

Pedro Sobral da Silva Filho

**Sintonia otimizada de ganhos para
controladores fuzzy multitarefas aplicados à
microrredes CA**

Viçosa, MG

2022

Pedro Sobral da Silva Filho

Sintonia otimizada de ganhos para controladores fuzzy multitarefas aplicados à microrredes CA

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 402 – Projeto de Engenharia II – e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Orientador: Rodolpho Vilela Alves Neves

Viçosa, MG

2022

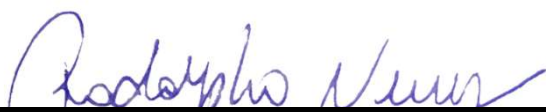
PEDRO SOBRAL DA SILVA FILHO

**SINTONIA OTIMIZADA DE GANHOS PARA CONTROLADORES
FUZZY MULTITAREFAS APLICADOS À MICRORREDES CA**

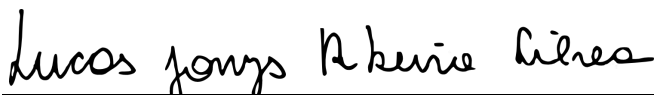
Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 402 – Projeto de Engenharia II e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 08 de abril de 2022.

COMISSÃO EXAMINADORA



Prof. Dr. Rodolpho Vilela Alves Neves - Orientador
Universidade Federal de Viçosa



Me. Lucas Jonys Ribeiro Silva - Coorientador
Universidade de São Paulo



Prof. Dr. Ricardo Quadros Machado - Membro
Universidade de São Paulo



Documento assinado digitalmente

Francisco Carlos Rodrigues Coelho

Data: 09/04/2022 09:19:32-0300

Verifique em <https://verificador.iti.br>

Prof. Dr. Francisco Carlos Rodrigues Coelho - Membro
Universidade Federal de São João del-Rei

Este trabalho é dedicado àqueles que buscam realizar seus sonhos.

Agradecimentos

Gostaria de agradecer, primeiramente, a todos meus professores do ensino médio, foram eles que me incentivaram incansavelmente a realizar um curso superior, sem o apoio e os conselhos que me foram dados, não seria quem sou hoje. Também agradeço aos meus familiares, pelo suporte durante o período da graduação, em especial aos meus irmãos: Luis Guilherme e Fernando, por quem sempre tive grande amor e carinho.

A todos os amigos que fiz durante minha estadia em Viçosa, em especial: Pablito, Calais, João Victor, Helena, Diuary, Leticinha, Botacin, Jhonathan e Uliana, com vocês compartilhei muitos momentos de alegria e dificuldade.

Ao professor Rodolpho, por todas as oportunidades e incentivos. Ao Jonys, por me dar suporte quando eu tinha dúvidas, você é um cara sensacional. Também a todos aqueles com quem tive a oportunidade de aprender algo novo.

Por fim, gostaria de agradecer a minha namorada Júlia, com ela tenho meus melhores momentos, sou muito feliz ao seu lado <3.

“No meio da dificuldade encontra-se a oportunidade.” (Autor desconhecido)

Resumo

As microrredes (MRs) podem ser definidas como sistemas que possuem localmente: cargas, sistemas armazenadores de energia e gerações distribuídas (GDs), podendo operar conectadas ou desconectadas da rede de distribuição (RD). Para que cada GD seja capaz de alimentar as cargas proporcionalmente à sua capacidade de fornecer de energia, podem ser aplicados diversos métodos de controle. Na literatura é comum encontrar métodos de controle baseados em *droop*, por não necessitar de comunicação entre as GDs. Contudo, a estratégia causa desvios de frequência e tensão que devem ser corrigidos por uma malha de controle secundária. Além disso, quando a MR opera conectada à RD, faz-se necessária a inserção de uma malha de controle terciária para controle do fluxo de potência. Já o controlador secundário fuzzy (CSF) atua substituindo os níveis secundário e terciário do controle hierárquico convencional baseado em *droop*. Por se tratar de um controlador fuzzy, as variáveis de entrada da lógica são primeiramente processadas em um estágio de normalização e ponderação. O presente trabalho se propõe a aplicar algoritmos heurísticos de otimização na etapa de fuzzyficação do controlador secundário multitarefas, com o objetivo de diminuir os erros de frequência, tensão, potência ativa e reativa do sistema, comparando as respostas obtidas com os valores originais. Os resultados de simulação mostraram que a estratégia de otimização, realizada de forma offline, apresentou uma redução de 10% no erro de potência ativa e 50% no erro de potência reativa, quando em modo conectado à RD. Contudo o erro de tensão aumentou em 33% no modo conectado e em 50% no modo desconectado.

Palavras-chaves: Microrredes CA; Controlador fuzzy; Algoritmos heurísticos de otimização.

Lista de figuras

Figura 1 – Estrutura básica de uma microrrede.	10
Figura 2 – Estrutura do controlador primário das GDs na microrrede CA.	15
Figura 3 – Estrutura do controlador secundário e terciário das GDs em microrredes CA.	16
Figura 4 – Estrutura do controlador secundário fuzzy.	17
Figura 5 – Estrutura completa da entrada do CSF.	18
Figura 6 – Fluxograma do funcionamento dos Algoritmos Genéticos.	19
Figura 7 – Estrutura básica que descreve o funcionamento do PSO.	21
Figura 8 – Fluxograma do funcionamento da Otimização por Exame de Partículas.	21
Figura 9 – Arquitetura da microrrede.	23
Figura 10 – Cenário completo do caso de estudo utilizando o PSO - Potência Ativa.	28
Figura 11 – Cenário completo do caso de estudo utilizando o PSO - Frequência.	28
Figura 12 – Cenário completo do caso de estudo utilizando o PSO - Potência Reativa.	29
Figura 13 – Cenário completo do caso de estudo utilizando o PSO - Tensão.	29
Figura 14 – Cenário completo do caso de estudo utilizando o GA - Potência Ativa.	31
Figura 15 – Cenário completo do caso de estudo utilizando o GA - Frequência.	31
Figura 16 – Cenário completo do caso de estudo utilizando o GA - Potência Reativa.	32
Figura 17 – Cenário completo do caso de estudo utilizando o GA - Tensão.	32

Lista de tabelas

Tabela 1 – Entradas do CSF proposto em Neves (2018).	17
Tabela 2 – Parâmetros elétricos da MR utilizada na simulação.	23
Tabela 3 – Parâmetros passados para a função “ga”.	24
Tabela 4 – Parâmetros passados para a função “ <i>particleswarm</i> ”.	25
Tabela 5 – Valores utilizados em Neves (2018) para os ganhos de entrada do CSF.	25
Tabela 6 – Tabela com os ganhos de entrada obtidos após a aplicação do PSO. . .	30
Tabela 7 – Tabela com os ganhos de entrada obtidos após a aplicação do GA. . . .	33
Tabela 8 – Tabela com os indicadores de desempenho para os casos conectado e ilhado (0,4 a 2,2 segundos).	34
Tabela 9 – Tabela com os indicadores de desempenho somente para o caso conectado (0,4 a 1,4 segundos).	35
Tabela 10 – Tabela com os indicadores de desempenho somente para o caso ilhado (1,55 a 2,2 segundos).	35

Lista de abreviaturas e siglas

CC	Corrente contínua.
CA	Corrente alternada.
CH	Controlador Hierárquico.
CSF	Controlador secundário fuzzy.
DER	<i>Distributed energy resources.</i>
ESS	<i>Energy storage system.</i>
FC	Função de custo.
GA	<i>Genetic Algorithm.</i>
GD	Geração distribuída.
HOA	<i>Heuristic optimization algorithm.</i>
MME	Ministério de Minas e Energia.
MR	Microrrede.
MSE	<i>Mean squared error.</i>
PSO	<i>Particle Swarm Optimization.</i>
Proinfa	Programa de Incentivo às Fontes Alternativas de Energia Elétrica.
RD	Rede de distribuição.
SEP	Sistema elétrico de potência.

Sumário


1	INTRODUÇÃO	10
1.1	Microrredes	11
1.2	Algoritmos Heurísticos de Otimização	12
1.3	Objetivos	13
2	REFERÊNCIAL TEÓRICO	14
2.1	Controlador hierárquico convencional	14
2.1.1	Controlador primário	14
2.1.2	Controlador secundário	15
2.1.3	Controlador terciário	16
2.2	Controlador secundário multitarefas	16
2.3	Algoritmos Genéticos	18
2.4	Otimização por enxame de partículas	19
2.5	Otimizações em Microrredes	22
3	MATERIAIS E MÉTODOS	23
3.1	Aplicação dos algoritmos de otimização	24
4	RESULTADOS E DISCUSSÃO	27
4.1	Resultados - Otimização por Enxame de Partículas	27
4.2	Resultados - Algoritmos Genéticos	30
4.3	Indicador de desempenho	33
4.4	Discussão	36
5	CONCLUSÃO	37
	REFERÊNCIAS	38

1 Introdução

O grande apelo por fontes de energias renováveis vem crescendo cada vez mais ao longo dos últimos anos, fomentado por fortes mudanças socioeconômicas. No cenário brasileiro, existem incentivos oferecidos pelo Governo Federal para o aumento da energia limpa através de, por exemplo, eliminação de impostos de importação para equipamentos de energia solar, permitindo o aumento da competitividade da fonte solar no mercado nacional.

Visando aumentar a sustentabilidade, o Ministério de Minas e Energia (MME) instituiu programas de incentivo às fontes renováveis como o Proinfa (Programa de Incentivo às Fontes Alternativas de Energia Elétrica) e o Renovabio (Política Nacional de Biocombustíveis). Neste contexto estão inseridas as microrredes (MR), podendo ser definidas, basicamente, como uma área que possui sistemas heterogêneos para geração de energia, sendo preferível a implementação de fontes de energias renováveis, sistemas de armazenamento de energia e cargas locais. Além disso, elas podem operar de forma conectada ou desconectada da rede. Sendo assim, elas oferecem uma solução viável para a integração de diferentes fontes conectadas ou não ao sistema elétrico de potência (SEP). A Figura 1 representa uma microrrede.

Figura 1 – Estrutura básica de uma microrrede.



Fonte: Acervo pessoal.

1.1 Microrredes

Atualmente, o conceito de MR está tomando um importante papel para permitir a integração entre diferentes gerações distribuídas (GD), incluindo, principalmente, fontes de energia renovável. A crescente integração das GDs significa uma modernização do SEP, proporcionando mais confiabilidade e sustentabilidade (LI et al., 2014), (BALAMURUGAN; SRINIVASAN, 2011).

Segundo o departamento do energia dos Estados Unidos as MRs são “Um grupo de cargas interconectadas e recursos de energia distribuídas (do inglês - DERs) com capacidades elétricas claramente definidas e que atua como uma única entidade controlável com respeito à rede, podendo se conectar ou desconectar da rede para habilitar o modo conectado ou ilhado, respectivamente”(DELIVERY; RELIABILITY, 2012). Entre os componentes de uma MR estão as cargas, DERs, chaves inteligentes, dispositivos de proteção, controladores, sistema de automação e comunicação (PARHIZI et al., 2015).

Os DERs mais considerados no conceito de microrredes são as GDs provindas de fontes de energia renovável e sistemas de armazenamento de energia (do inglês - ESS). Dentre as fontes de energia renovável disponíveis, as mais amplamente utilizadas são a geração eólica e fotovoltaica, por serem mais compactas e podendo ser conectadas em qualquer ponto da rede de distribuição (RD) (ROCABERT et al., 2012).

Devido à dependência das condições meteorológicas que os painéis fotovoltaicos e as turbinas eólicas possuem, a geração de energia acontece de modo intermitente. Nesses casos, a associação às ESSs aumenta a confiabilidade, eficiência e as características transitórias da energia elétrica através do balanço de potências (PATRAO et al., 2015).

As MRs podem ser classificadas como sendo de corrente contínua (CC), corrente alternada (CA) ou híbridas (AGNOLETTO, 2020). Considerando o caso das MRs CA, devido ao fato de grande parte das fontes de energia renovável e os ESSs funcionarem em corrente contínua, é necessária a conversão para corrente alternada através de conversores CC-CA (LU et al., 2013).

No caso onde a MR possui GDs operando em paralelo é necessária uma estratégia que permita o compartilhamento de cargas entre elas (BIDRAM; LEWIS; DAVOUDI, 2014). Um método amplamente utilizado para compartilhamento de cargas em MR é através do controlador droop, que permite o compartilhamento sem a necessidade de comunicação entre as GDs. Porém, esse controlador pode causar desvios de frequência e tensão quando há variações na carga, para o caso onde a linha de transmissão é considerada altamente indutiva.

Para corrigir os desvios de frequência e tensão causados quando há variação de carga, aplica-se uma malha de controle superior ao droop, conhecida como malha de controle secundário. Além disso, quando a MR opera em modo conectado à rede de distribuição e

deseja-se exportar energia é necessária uma malha de controle superior à malha de controle secundário, conhecida como malha de controle terciário.

Portanto, em MRs que utilizam o droop para compartilhamento de cargas podem ser necessários 3 controladores, na literatura, esse método com até 3 controladores é denominado de controlador hierárquico (CH), com o controlador primário sendo o droop, o secundário sendo o responsável por corrigir os desvios de frequência e tensão causados pelo droop e, por fim, o controlador terciário responsável pelo controle do fluxo de energia no modo conectado à RD.

Na literatura podem ser encontrados trabalhos que utilizam a lógica fuzzy aplicada ao controle de MRs como em (AHMADI; SHOKOOHI; BEVRANI, 2015) e (NEVES, 2018). Em Neves (2018) é proposto um controlador fuzzy capaz de substituir os níveis secundário e terciário do controlador hierárquico. Dessa forma, não há a necessidade de chaveamento entre os níveis de controle quando há alteração entre o modo ilhado e o conectado. Contudo, devido ao fato de se tratar de um controlador não linear, é extremamente laborioso analisar e encontrar valores adequados para os parâmetros a serem utilizados.

1.2 Algoritmos Heurísticos de Otimização

Devido à alta complexidade em se trabalhar com certas variáveis de controle em controladores não lineares, os algoritmos heurísticos de otimização (do inglês - HOAs) são amplamente aplicados para otimizá-las. Os HOAs representam um grupo de algoritmos inteligentes que buscam uma solução ótima baseados em fenômenos naturais, como os princípios evolutivos propostos por Darwin ou então mimetizando fenômenos naturais (NIU; WAN; XU, 2014). Dessa forma, a utilização de HOAs na escolha dos parâmetros de um controlador fuzzy são uma ótima alternativa.

Pelo fato de o controlador fuzzy ser baseado em sentenças de regras linguísticas sua sintonia pelos métodos analíticos clássicos não é tão simples quando comparada com os controladores tradicionais. Dessa forma, é difícil inferir o comportamento dinâmico do sistema em torno de um dado ponto. Sendo assim, os métodos heurísticos de otimização tornam-se de grande valia na sintonização desses controladores.

Algoritmos heurísticos de otimização como os Algoritmos Genéticos (do inglês - GA) e a Otimização por Enxame de partículas (do inglês - PSO) possuem uma extensa aplicação em diversos campos do conhecimento e podem ser encontrados em vários problemas que envolvem otimização de problemas complexos. Em Sindhiya e Gunasundari (2014) o GA é utilizado em um sistema de diagnóstico de doenças, em Antunes e Azevedo (2014) é feito um estudo da aplicação do GA em otimizações de sistemas aerodinâmicos, já em Zhang, Wang e Ji (2015) são apresentadas as aplicações do PSO em campos como: Engenharia Elétrica, Sistemas de Controle, Teoria da Comunicação, entre outros.

Em Burke et al. (2014) é apresentada uma introdução às otimizações e técnicas de tomada de decisão, nos capítulos referentes ao GA e PSO é feita uma descrição minuciosa do comportamento de cada algoritmo, além disso, são citados diversos artigos de várias áreas do conhecimento onde tais algoritmos são aplicados.

Portanto, o presente trabalho se justifica devido à dificuldade em descrever os controladores fuzzy pelos métodos matemáticos convencionais e à característica do PSO e do GA em lidarem com otimizações de problemas complexos.

1.3 Objetivos

Este trabalho propõe ajustar os ganhos de entrada na etapa de fuzificação de um controlador fuzzy, através da aplicação de algoritmos heurísticos de otimização. O objetivo geral consiste em aplicar os algoritmos *Particle Swarm Optimization* (PSO) e *Genetic algorithm* (GA) tanto na etapa de fuzzyficação do controlador secundário multitarefas proposto em Neves (2018) para encontrar valores que aproximem melhor a resposta do sistema à referência das variáveis de tensão, frequência, potência ativa e reativa.

Os objetivos específicos deste trabalho são:

- Estudar o comportamento dos algoritmos heurísticos de otimização PSO e GA em controladores fuzzy e aplicá-los no controlador secundário multitarefas.
- Avaliar o desempenho de cada algoritmo de otimização considerando os resultados obtidos.
- Selecionar os melhores valores encontrados para o controlador através da comparação entre os indicadores de desempenho.

2 Referencial Teórico

Para que as GDs da MR possam entregar energia de qualidade às cargas é necessária a aplicação de métodos de controle capazes de coordenar o balanço de energia. Um dos métodos amplamente empregados no controle de MRs é conhecido como: controle hierárquico (CH) que baseia-se na estratégia de compartilhamento de carga realizada por um controlador *droop*.

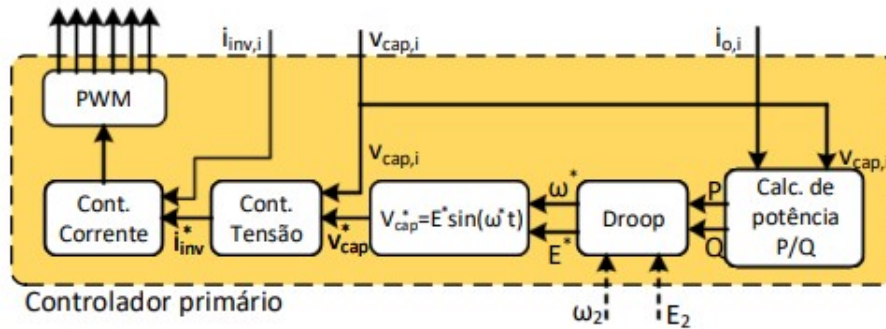
2.1 Controlador hierárquico convencional

O CHC consiste basicamente de 3 camadas: controlador primário, secundário e terciário. Cada um atuando em uma escala de tempo diferente (BIDRAM; LEWIS; DAVOUDI, 2014)., aumentando do primário para o terciário. Apesar de não ser tão mencionado, existe um nível de controle mais básico, denominado controle de nível zero, responsável pelas malhas de corrente e tensão para o controle dos inversores.

2.1.1 Controlador primário

O nível primário é responsável pelo controle dos transientes que afetam a estabilidade do sistema (GUERRERO et al., 2012). Esse nível é responsável pelo ajuste da tensão e da frequência que serão passados para a referência do controlador de nível zero. O controlador *droop* é amplamente utilizado nesse nível devido à sua capacidade de oferecer compartilhamento de cargas, no caso onde há mais de uma GD, sem a necessidade de bandas de comunicação. Esse controlador passa a referência de tensão e frequência para o controlador de tensão através de cálculos considerando as potências ativa e reativa oferecidas pela GD. A Figura 2 representa a estrutura descrita.

Figura 2 – Estrutura do controlador primário das GDs na microrrede CA.



Fonte: Adaptado de Neves (2018).

Sendo $I_{inv,i}$, $V_{cap,i}$ e $I_{o,i}$ a corrente no indutor e a tensão no capacitor do filtro LC na saída do inversor e a corrente entregue no PCC, respectivamente; P e Q são os valores de potência ativa e reativa, respectivamente; ω e E são os valores de frequência e tensão. Todos os termos que possuem “*” são valores de referência das variáveis já citadas.

Neste trabalho a impedância da linha de transmissão será considerada altamente indutiva, sendo assim equação do controlador droop é dada por:

$$\omega = \omega_o - m\Delta P, \quad (2.1)$$

$$E = E_o - n\Delta Q, \quad (2.2)$$

onde m e n são os coeficientes do droop para frequência e tensão, respectivamente e ΔP e ΔQ são as variações de potência ativa e reativa, respectivamente.

2.1.2 Controlador secundário

O controlador secundário é responsável pela correção dos desvios de frequência e tensão causados pelo nível primário, regulando essas variáveis sempre que ocorrerem variações na carga ou na energia fornecida pela GD (GUERRERO et al., 2012). Essa regulação pode ser feita através da utilização de controladores PIs, a partir da leitura da tensão e frequência no ponto de acomplamento comum e utilizando valores de referência previamente estabelecidos para ambas as variáveis. A saída desse controlador é somada à equação característica do droop, conforme apresentado nas equações abaixo:

$$\omega = \omega_o - m\Delta P + \omega_2, \quad (2.3)$$

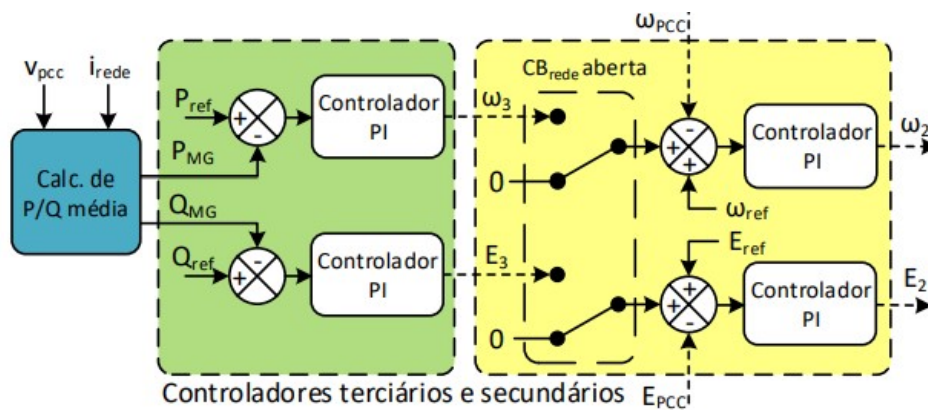
$$E = E_o - n\Delta Q + E_2, \quad (2.4)$$

onde ω_2 e E_2 são os valores de correção provenientes do controlador secundário e que serão somados na equação do *droop*.

2.1.3 Controlador terciário

O controlador terciário é responsável pela otimização da operação econômica, exportando ou importando potência da rede quando a microrrede está operando em modo conectado com a rede de distribuição (GUERRERO et al., 2010). A partir do valor de referência para a potência a ser exportada/importada, da leitura dos valores de potência nos barramentos e da atuação de controladores PIs são passadas novas referências para o nível secundário, conforme pode ser observado na Figura 3.

Figura 3 – Estrutura do controlador secundário e terciário das GDs em microrredes CA.



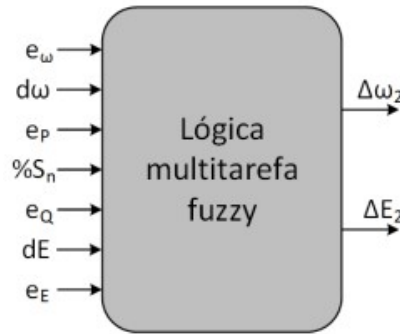
Fonte: Adaptado de Neves (2018).

Sendo CB_{rede} a chave responsável pela conexão/desconexão da rede de distribuição. Os subscritos “ pcc ” referem-se aos valores lido no ponto de acoplamento comum e “ ref ” aos valores de referência.

2.2 Controlador secundário multitarefas

Em Neves (2018) é proposta a utilização de um controlador secundário fuzzy (CSF), ele centraliza as funções dos níveis secundário e do terciário do CHC sem a necessidade de chaveamentos entre os níveis de controle. Para isso, utiliza-se a estrutura apresentada na Figura 4.

Figura 4 – Estrutura do controlador secundário fuzzy.



Fonte: Adaptado de Neves (2018).

Esse controlador possui sete entradas e duas saídas. A escolha das variáveis de entrada do controlador foi realizada de modo que elas possam ser amostradas localmente. As entradas e saídas do CSF são apresentadas na Tabela 1.

Tabela 1 – Entradas do CSF proposto em Neves (2018).

e_ω	Erro de frequência
d_ω	Gradiente de frequência
e_P	Erro de potência ativa
S_n	Potência aparente
e_Q	Erro de potência reativa
d_E	Gradiente de tensão
e_E	Erro de tensão
$\Delta\omega_2$	parcela da frequência a ser somada no <i>droop</i>
ΔE_2	parcela da tensão a ser somada no <i>droop</i>

As tensões e correntes utilizadas para os cálculos das potências são medidas no PCC da microrrede. As saídas do CSF são as parcelas a serem somadas na equação do *droop*, conforme apresentado nas equações (2.3) e (2.4).

O erro de frequência (e_ω) e o erro de tensão (e_E), são a diferença entre os valores de referências nominais (ω_{ref} e E_{ref}) e os valores medidos no PCC (ω_{pcc} e E_{pcc}) ponderados por ganhos de entrada ($K_{e\omega}$ e K_{eE}), conforme as equações (2.5) e (2.6).

$$e_\omega = K_{e\omega}(\omega_{ref} - \omega_{pcc}) . \quad (2.5)$$

$$e_E = K_{eE}(E_{ref} - E_{pcc}) , \quad (2.6)$$

Quando ocorre a conexão com a RD e uma injeção de potência é possível, os erros de potência ativa (e_P) e reativa (e_Q), são a diferença entre os valores de referências que se

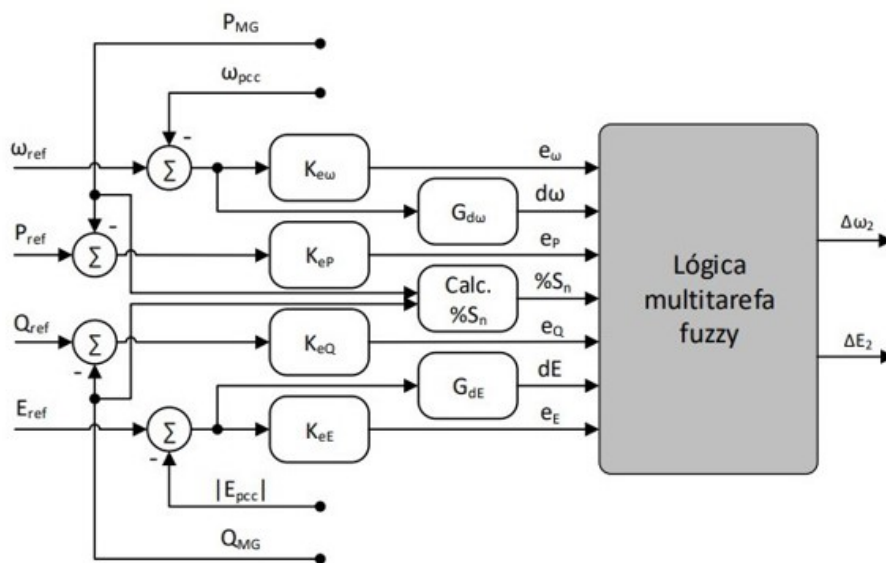
deseja exportar (P_{ref} e Q_{ref}) e os valores medidos no PCC (P_{MG} e Q_{MG}) ponderados por ganhos de entrada (K_{eP} e K_{eQ}), conforme as equações (2.7) e (2.8).

$$e_P = K_{eP}(P_{ref} - P_{MG}) , \quad (2.7)$$

$$e_Q = K_{eQ}(Q_{ref} - Q_{MG}) . \quad (2.8)$$

Dessa forma, a estrutura da Figura 4 poder ser representada por:

Figura 5 – Estrutura completa da entrada do CSF.



Fonte: Adaptado de Neves (2018).

O presente trabalho aplica HOAs a fim de otimizar os valores de frequência e tensão do PCC, no caso da MR ilhada e otimizar os valores de potência ativa e reativa que são exportados à RD, no caso da MR conectada. Para isso é elaborada uma função de custo que contém como parâmetros: e_ω , e_E , e_P e e_Q .

Conforme descrito anteriormente, os erros (e_ω , e_E , e_P e e_Q), dependem de valores que são lidos no PCC (ω_{pcc} , E_{pcc} , P_{MG} e Q_{MG}), valores de referência (ω_{ref} , E_{ref} , P_{ref} e Q_{ref}) e os ganhos de entrada ($K_{e\omega}$, K_{eE} , K_{eP} , K_{eQ}). Portanto, este trabalho trata, essencialmente, de encontrar valores otimizados para os ganhos de entrada do CSF através da aplicação do GA e do PSO.

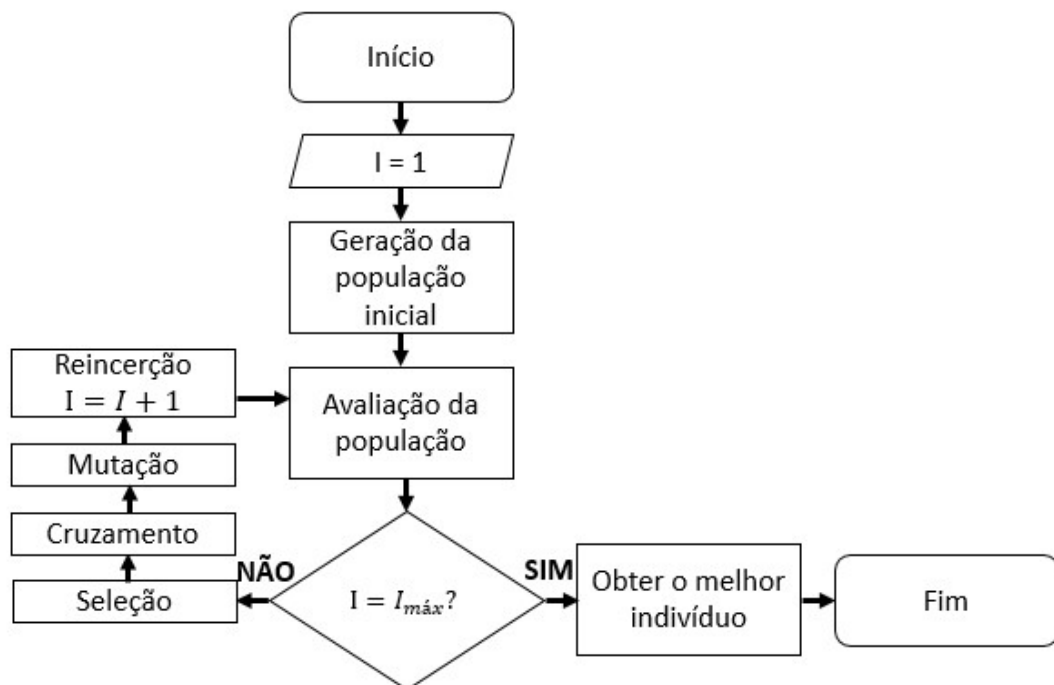
2.3 Algoritmos Genéticos

Os algoritmos genéticos foram introduzidos em Holland et al. (1975) e são baseados em mecanismos genéticos e nos princípios evolutivos propostos por Darwin para a seleção

natural. Trata-se de um algoritmo baseado em população, a qual é transformada de um conjunto inicial de indivíduos para um conjunto final. Existem diversas variantes deste algoritmo, porém sua ideia básica é emular a reprodução, mutação e seleção dos melhores indivíduos dentro da população. A solução ótima é encontrada nos genes do melhor indivíduo da população.

Como o GA é baseado em um método de busca estocástica, não existe um critério específico para definir sua convergência, a prática frequentemente adotada é para o algoritmo depois de um dado número de gerações ou quando não há grandes alterações nas suas respostas. A sua estrutura básica é apresentada na Figura 6.

Figura 6 – Fluxograma do funcionamento dos Algoritmos Genéticos.



Fonte: Acervo pessoal.

O pseudocódigo do algoritmo pode ser dado por:

2.4 Otimização por enxame de partículas

A otimização por exame de partículas foi introduzida em Kennedy e Eberhart (1995) e Eberhart e Kennedy (1995). Esse algoritmo reproduz o comportamento de bandos de pássaros e cardumes de peixes na busca por alimento, onde o ponto que contém o alimento seria a solução ótima. Nessa técnica o comportamento do indivíduo mais próximo do alimento influencia os demais indivíduos, fazendo com que se aproximem da comida. Uma analogia interessante é imaginar que alguém joga vários grãos de milho em algum

Algoritmo 1: GA**Dados:**

Iniciar o número da geração, $i = 1$;

Gerar uma população aleatória de cromossomos P_i ;

1 **enquanto** *O número máximo de gerações não foi alcançado* **faça**

2 | Calcular a função objetivo de cada cromossomo e a sua probabilidade de sobrevivência;

3 | Realizar a seleção dos melhores indivíduos da população P_i ;

4 | Aplicar o operador de cruzamento à população P_i , gerando a população P_{i+1} ;

5 **fim**

Resultado: Selecionar o melhor indivíduo

local aberto, temos certeza de que em algum momento vários pássaros vão estar lá se alimentando. Eles procuram comida aleatoriamente indo de árvore em árvore, até acharem comida e de alguma forma todo o seu bando fica sabendo.

O que esse algoritmo faz é definir um espaço de busca multidimensional que será explorado pelo enxame de partículas. Inicialmente, as partículas estão em posições aleatórias dentro desse espaço definido. Essas posições podem ser representadas pelo vetor $\vec{X} = (X_{i1}, X_{i2}, \dots, X_{id})$. Além da posição, cada partícula também se inicia com uma velocidade aleatória representada pelo vetor $\vec{V} = (V_{i1}, V_{i2}, \dots, V_{id})$. Após cada iteração as posições das partículas são atualizadas de acordo com (2.9).

$$\vec{X}_{id}(t+1) = \vec{X}_{id}(t) + \vec{V}_{id}(t+1) \quad (2.9)$$


A variável t é o índice da iteração, $i = 1, \dots, N_g$, sendo N_g o número de parâmetros ou dimensões de uma partícula. A busca pelo ponto de ótimo se dá através da alteração da velocidade das partículas e, conseqüentemente da sua posição. A velocidade $\vec{V}_{id}(t+1)$ é influenciada pela melhor posição que a partícula já obteve durante as iterações, definida por \vec{P}_{best} , assim como a posição da partícula mais bem posicionada da iteração em questão, definida por \vec{N}_{best} . Através da soma ponderada desses vetores, chega-se ao valor de $\vec{V}_{id}(t+1)$ e, conseqüentemente, a $\vec{X}_{id}(t+1)$. A Figura 7 descreve o processo.

Dessa forma, $\vec{V}_{id}(t+1)$ pode ser descrito por (2.10):

$$\begin{aligned} \vec{V}_{id}(t+1) = & \omega \cdot \vec{V}_{id}(t) + \\ & a_1 \cdot \text{random}[0, 1] \cdot [\vec{P}_{best} - \vec{X}_{id}(t)] + \\ & a_2 \cdot \text{random}[0, 1] \cdot [\vec{N}_{best} - \vec{X}_{id}(t)] \end{aligned} \quad (2.10)$$

Onde ω é um fator de inércia, a_1 uma constante representando o coeficiente cognitivo, a_2 uma constante representando o coeficiente social e $\text{random}[0,1]$ um valor aleatório entre 0 e 1, com distribuição uniforme.

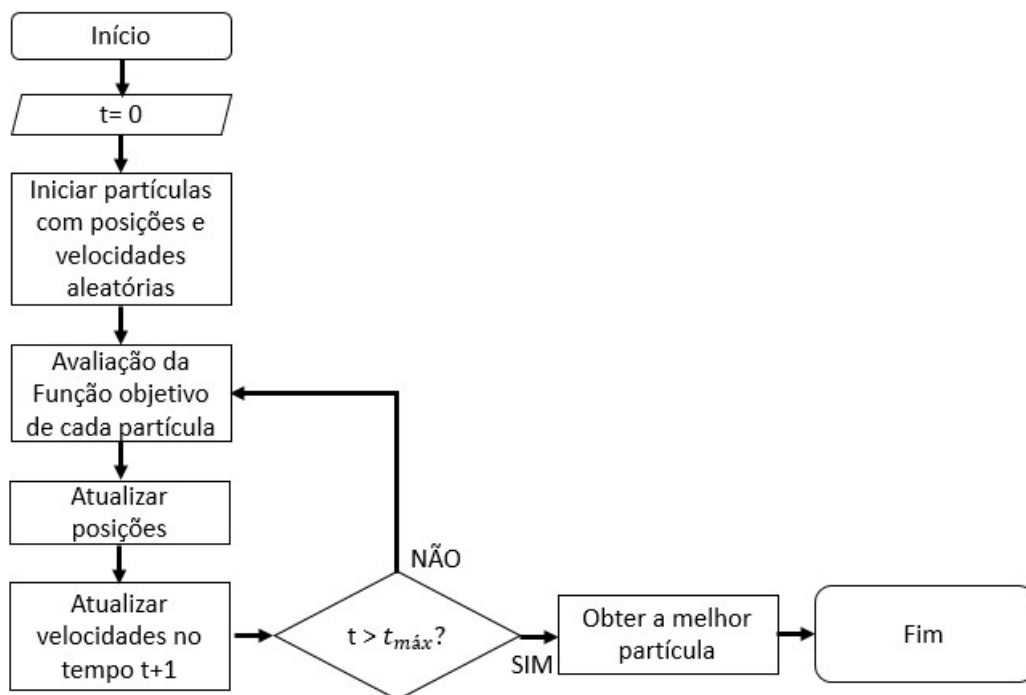
Figura 7 – Estrutura básica que descreve o funcionamento do PSO.



Fonte: Acervo pessoal.

O algoritmo de otimização por enxame de partículas pode ser sintetizado pelo fluxograma apresentado na Figura 8.

Figura 8 – Fluxograma do funcionamento da Otimização por Exame de Partículas.



Fonte: Acervo pessoal.

O pseudocódigo do algoritmo pode ser dado por:

Algoritmo 2: PSO**Dados:**

Inicializar um conjunto de partículas em um tempo $t = 0$, com velocidades e posições aleatoriamente distribuídas dentro do espaço de busca;

- 1 **enquanto** *O número máximo de iterações não foi alcançado* **faça**
- 2 Avaliar a função objetivo de cada uma das partículas da população;
- 3 Atualizar a melhor posição de cada partícula individualmente e a melhor posição global;
- 4 Atualizar a posição de cada partícula no tempo $t+1$ baseado nas posições e velocidade no tempo t ;
- 5 **fim**

Resultado: Selecionar a melhor partícula;

2.5 Otimizações em Microrredes

Algoritmos baseados em inteligência computacional como GA e o PSO têm sido aplicados com sucesso à diferentes problemas envolvendo sistemas de potência, isso se deve às características não lineares, interconectadas e complexas encontradas nesses sistemas (ABRAHAM; DAS, 2010).

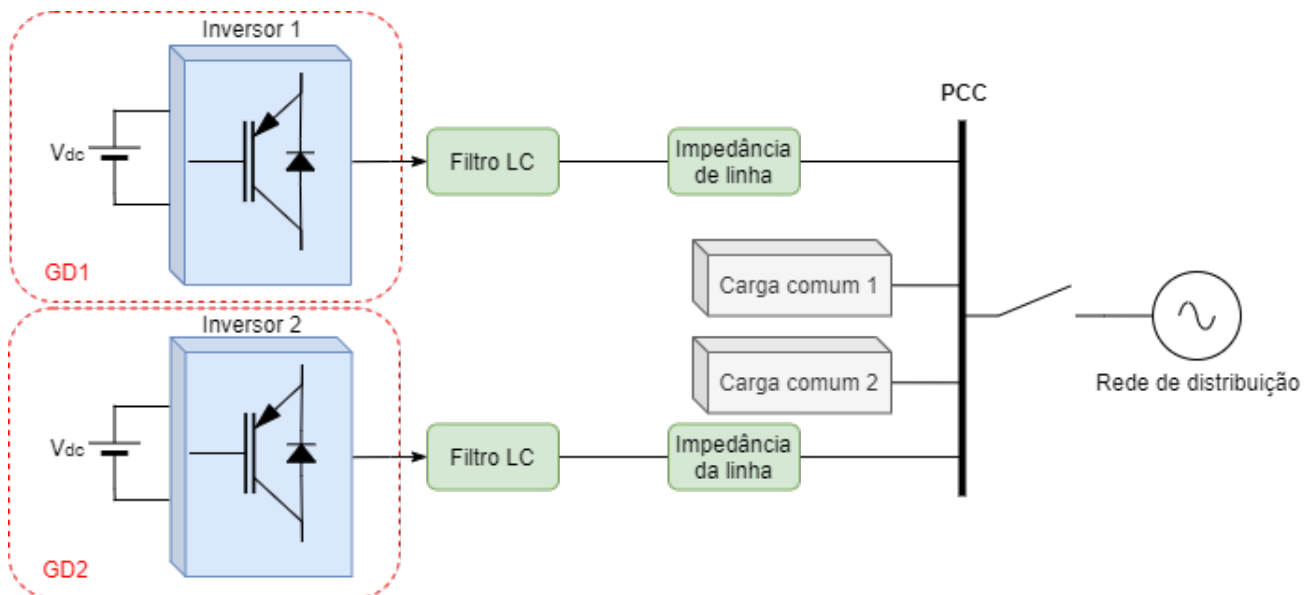
Em Ebrahim et al. (2018) utiliza-se o algoritmo PSO para o ajuste ótimo dos ganhos de um controlador PI atuando no nível secundário de uma microrrede autônoma. Já em hassan2010optimal o PSO é aplicado para otimizações no modo conectado e ilhado, sendo que no modo conectado a otimização é realizada no design dos filtros LC, nos parâmetros dos controladores e na resistência de amortecimento; já no modo ilhado são otimizados os parâmetros dos controladores e os coeficientes do droop. Em Shan et al. (2021) é proposto um controle preditivo unificado para a tensão e a corrente para o modo conectado e ilhado, sendo que a função de custo (FC) a ser minimizada pelo controlador preditivo é mantida a mesma para os dois modos, contudo quando há alteração entre modo conectado e ilhado os parâmetros da FC tornam-se diferentes, o que implica em uma mudança na FC, além disso, não é especificado qual o algoritmo utilizado.

O presente trabalho se propõe a otimizar os ganhos de entrada ($K_{e\omega}$, K_{eE} , K_{eP} , K_{eQ}) CSF tanto para o modo conectado, quanto para o ilhado sem necessidade de alterar as estruturas dos controladores e utilizando apenas uma função de custo, que não se modificará na alteração entre os modos conectado ou ilhado.

3 Materiais e Métodos

Todas as descrições técnicas e valores utilizados para a microrrede, além dos detalhes sobre o funcionamento do controlador secundário fuzzy multitarefas podem ser encontrados em Neves (2018). A microrrede utilizada possui duas fontes de geração baseadas em sistemas de armazenamento com duas cargas compartilhadas entre si. Na saída dos inversores existem filtros LC e a impedância da linha é considerada altamente indutiva. Todas as simulações foram realizadas em ambiente *simulink*. A Figura 9 apresenta o sistema descrito.

Figura 9 – Arquitetura da microrrede.



Fonte: Acervo pessoal.

Alguns dados básicos da MR são apresentados na Tabela 2.

Tabela 2 – Parâmetros elétricos da MR utilizada na simulação.

Tensão (rms)	220 V
Frequência	60 Hz
Coeficiente <i>droop</i> da frequência	1%
Coeficiente <i>droop</i> da tensão	1%
Potência das cargas	0.33 p.u.

Através da utilização do controlador secundário multitarefas é possível atuar tanto no modo ilhado quanto no modo conectado à rede de distribuição. No caso ilhado, o objetivo é manter os níveis de tensão e frequência com a menor distorção possível. Já no modo conectado, o interesse é em regular melhor os níveis de potências que estão sendo

enviados à rede de distribuição, uma vez que os valores de tensão e frequência são ditados pela rede.

Afim de avaliar o desempenho do sistema, são realizadas comparações entre o controlador com os ganhos originais ($K_{e\omega}$, K_{eP} , K_{eQ} e K_{eE}) do trabalho de Neves (2018) e com os ganhos otimizados pelos HOAs ($K_{e\omega opt}$, $K_{eP opt}$, $K_{eQ opt}$ e $K_{eE opt}$). Para isso, será utilizado um caso de estudo onde há a conexão e desconexão com a rede e, em seguida, a conexão de cargas ao PCC.

3.1 Aplicação dos algoritmos de otimização

O emprego dos HOAs foi realizado através da *Global Optimization Toolbox* do MATLAB, utilizando-se a função “ga” para aplicação dos algoritmos genéticos, mais informações em ga (2019) e a função “particleswarm” para aplicação da otimização por enxame de partículas, mais informações em particleswarm (2014). Os parâmetros passados para cada uma das funções são apresentados nas Tabelas 3 e 4:

Tabela 3 – Parâmetros passados para a função “ga”.

<i>Fun</i>	A F.C. definida
<i>Nvars</i>	4
<i>A</i>	-
<i>B</i>	-
<i>Aeq</i>	-
<i>Beq</i>	-
<i>lb</i>	[400 0.1 1 1]
<i>ub</i>	[700 1.5 5 5]
<i>nonlcon</i>	-
<i>intcon</i>	-
<i>MaxGenerations</i>	15
<i>MaxStallGenerations</i>	10
<i>Display</i>	iter, PlotFcns
<i>PlotFcn</i>	@gaplotbestindiv
<i>PlotInterval</i>	1
<i>PopulationSize</i>	60

Tabela 4 – Parâmetros passados para a função “*particleswarm*”.

<i>Fun</i>	A F.C. definida
<i>Nvars</i>	4
<i>lb</i>	[400 0.1 1 1]
<i>ub</i>	[700 1.5 5 5]
<i>Display</i>	iter
<i>MaxIterations</i>	15
<i>MaxStallIterations</i>	10
<i>PlotFcn</i>	pswplotbestf
<i>SwarmSize</i>	60

A escolha dos valores iniciais para a aplicação dos algoritmos heurísticos de otimização é uma etapa muito importante do processo, contudo não existe uma metodologia a ser seguida para definí-los. Dessa forma, os valores escolhidos para a inicialização dos ganhos de entrada nos HOAs são os que já estavam sendo utilizados. Os valores são apresentados na Tabela 5 abaixo:

Tabela 5 – Valores utilizados em Neves (2018) para os ganhos de entrada do CSF.

$K_{e\omega}$	500
K_{eP}	1
K_{eQ}	1
K_{eE}	2

São utilizadas 15 épocas com 60 partículas/indivíduos para ambos os algoritmos. A pequena quantidade de épocas é devido à limitada disponibilidade de recursos para realizar as simulações. São utilizadas 4 funções de custo diferentes para a aplicação dos algoritmos, essa escolha objetiva possibilitar diferentes alternativas de investigação durante a aplicação dos algoritmos, por se tratar da aplicação de algoritmos heurísticos, quanto mais possibilidades de busca são oferecidas, maior a chance de encontrar um resultado satisfatório, mais informações sobre essa filosofia de funcionamento dos HOAs podem ser encontradas no *no free lunch theorem* ou simplesmente NFL apresentado em Wolpert e Macready (1997). Tal teorema estabelece que não há uma metodologia para tratar problemas de otimização, sendo necessárias formulações de várias hipóteses para alcançar um melhor desempenho. Com isso em mente, são propostas as seguintes funções de custo:

$$ISE = \int_0^t erro^2(t) dt. \quad (3.1)$$

O ISE tem a característica de atuar em grandes proporções para erros maiores e pequenas proporções para erros menores, com uma resposta rápida e com oscilações.

$$IAE = \int_0^t |erro(t)| dt. \quad (3.2)$$

O IAE tem a característica de um amortecimento razoavelmente suave, com um máximo sobressinal sem muita oscilação na resposta.

$$ITSE = \int_0^t \text{erro}^2(t) dt. \quad (3.3)$$

O ITSE atua em pequenas proporções para erros iniciais grandes e à medida que aumenta o tempo na resposta transitória, atua em maiores proporções.

$$ITAE = \int_0^t t|\text{erro}(t)| dt. \quad (3.4)$$

Por fim o ITAE se caracteriza por reduzir grandes erros iniciais e de regime, o que torna o máximo sobressinal pequeno e as oscilações amortecidas.

O erro utilizado em cada uma das FC é composto pela soma dos erros da potência ativa, reativa, tensão e frequência. Devido à diferença de magnitude entre os erros todos eles são normalizados. No caso do modo conectado as potências são normalizadas com base na potência de referência que será fornecida à rede e no modo ilhado a tensão e a frequência são normalizados em relação aos seus respectivos valores de nominais.

Sendo assim, a função de custo utilizada para encontrar o ponto de ótimo considerando as 4 variáveis analisadas, pode ser generalizada por:

$$\mathbf{Função\ de\ custo} = \frac{1}{T} \cdot \left(\int_0^t E_{n\omega} dt + \int_0^t E_{nP} dt + \int_0^t E_{nQ} dt + \int_0^t E_{nv} dt \right), \quad (3.5)$$

onde T é o período de tempo utilizado na simulação e E_n denota o erro normalizado da variável em questão. A partir de (3.6) são derivadas as funções de custo propostas para a otimização, por exemplo, quando o modelo a ser utilizado for o ISE a FC terá o seguinte formato:

$$\mathbf{Função\ de\ custo} = \frac{1}{T} \cdot \left(\int_0^t E_{n\omega}^2 dt + \int_0^t E_{nP}^2 dt + \int_0^t E_{nQ}^2 dt + \int_0^t E_{nv}^2 dt \right), \quad (3.6)$$

A aplicação do IAE, ITSE e ITAE é feita de forma análoga à apresentada para a ISE.

A aplicação do PSO, por exemplo, é realizada através do repasse do valor de cada partícula às variáveis dos ganhos de entrada ($K_{e\omega}$, K_{eP} , K_{eQ} e K_{eE}), então simula-se a operação desejada para a microrrede e, após o término da simulação são obtidos os valores de erro (e_ω , e_P , e_Q e e_E), de posse desses valores, é possível avaliar a partícula com base no valor da sua função de custo, então o algoritmo segue seu conjunto de instruções lógicas. A aplicação do GA segue o mesmo procedimento descrito para o PSO.

4 Resultados e Discussão

O caso de estudo utilizado para realizar as otimizações é o de uma MR em dois momentos distintos. No primeiro momento ela está conectada à RD e começa a exportar potência ativa, na sequência começa a exportar potência reativa. Em um dado instante a MR desconecta-se da RD e então cargas locais são acopladas e desacopladas do PCC, vide Figura 9.


É importante atentar-se ao fato de que a otimização é realizada para a MR tanto conectada como desconectada da RD. Esta abordagem pode afetar o resultado final, pois caso fosse considerado isoladamente apenas o caso conectado ou o desconectado, outra função de custo deveria ser modelada, buscando priorizar as variáveis mais pertinentes de cada modo.

A seguir serão apresentados os resultados obtidos pela aplicação do PSO, seguidos dos resultados obtidos pelo GA. A critério de comparação, serão apresentadas as respostas de cada algoritmo para todas as funções de custo propostas no Capítulo 3, assim como os resultados obtidos pelos valores originais do trabalho.

4.1 Resultados - Otimização por Enxame de Partículas

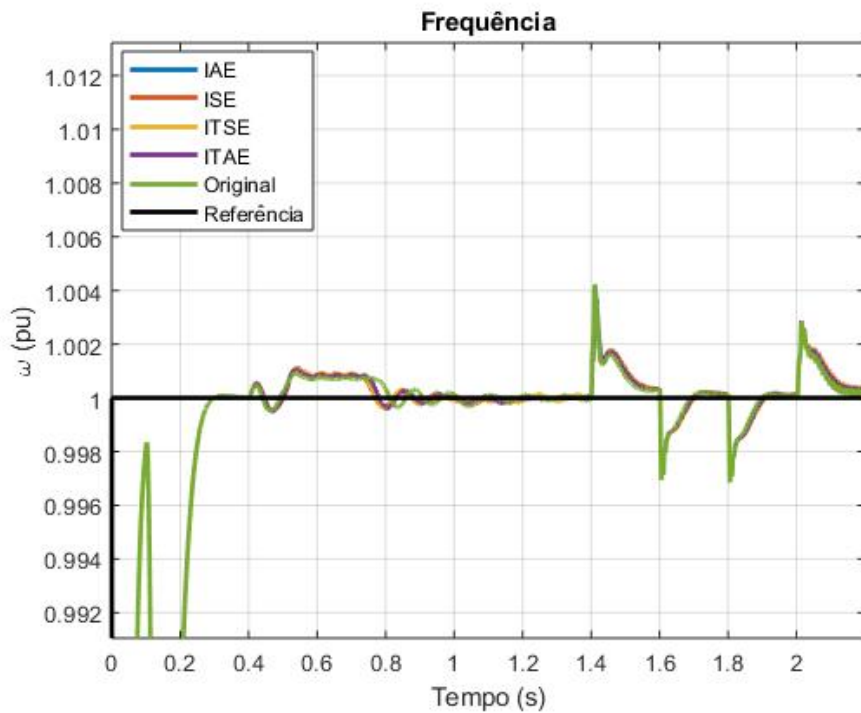
Todas as grandezas que serão apresentadas foram convertidas para o sistema p.u. No caso estudado, em 0,4 segundos a MR conecta-se à RD, em 0,5 segundos a referência de potência ativa é alterada de 0 para 3000 W, em 1 segundo a referência de potência reativa é alterada de 0 para 880 VAr, em 1,4 segundos a MR é desconectada da RD, em 1,6 segundos uma carga é acoplada ao PCC, em 1,8 segundos outra carga é acoplada e em 2 segundos uma das cargas é retirada. Os resultados obtidos para o caso de estudo onde se utiliza o PSO são apresentados abaixo.

Figura 10 – Cenário completo do caso de estudo utilizando o PSO - Potência Ativa.



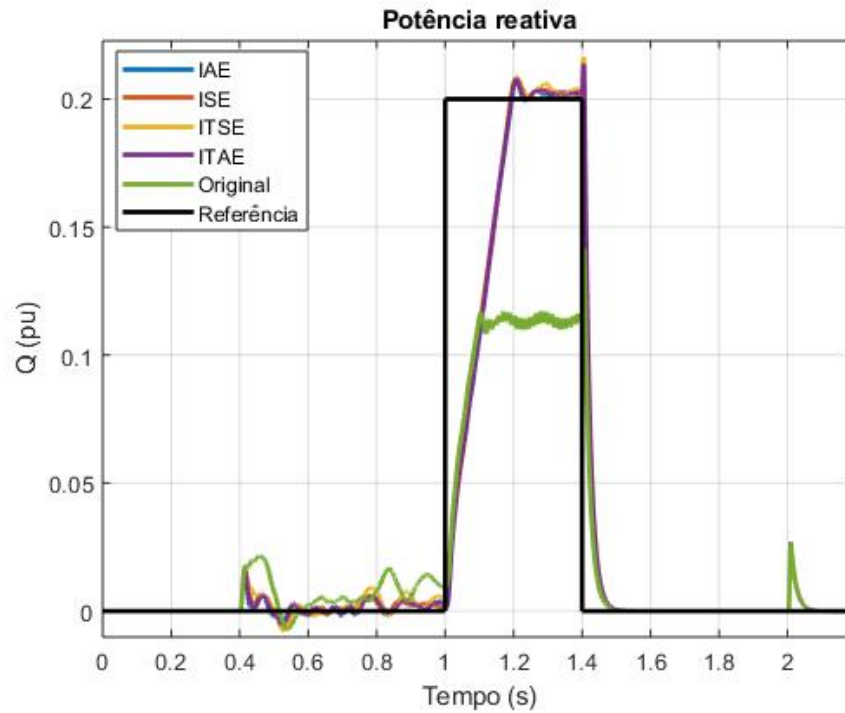
Fonte: Acervo pessoal.

Figura 11 – Cenário completo do caso de estudo utilizando o PSO - Frequência.




Fonte: Acervo pessoal.

Figura 12 – Cenário completo do caso de estudo utilizando o PSO - Potência Reativa.



Fonte: Acervo pessoal.

Figura 13 – Cenário completo do caso de estudo utilizando o PSO - Tensão.



Fonte: Acervo pessoal.

No modo conectado, percebe-se que as respostas obtidas após a otimização para a potência ativa e a frequência não apresentaram grandes diferenças em comparação com os valores originais do trabalho de Neves (2018), sendo que as referências foram atingidas para ambos os casos, com pequenas oscilações para a potência ativa. Já as repostas obtidas após a otimização para a potência reativa e a tensão apresentam grandes diferenças quando comparadas aos valores originais do trabalho de Neves (2018). A potencia reativa atingiu sua referência com precisão bem superior após a otimização, já a tensão apresentou maior erro após a otimização.

No caso da MR operando ilhada com entrada e saída de cargas, a única variável que apresentou resultados divergentes em comparação com o trabalho original, foi a tensão, sendo que seu erro aumentou após a otimização.

Os valores obtidos para os ganhos de entrada através do PSO são apresentados na Tabela 6.

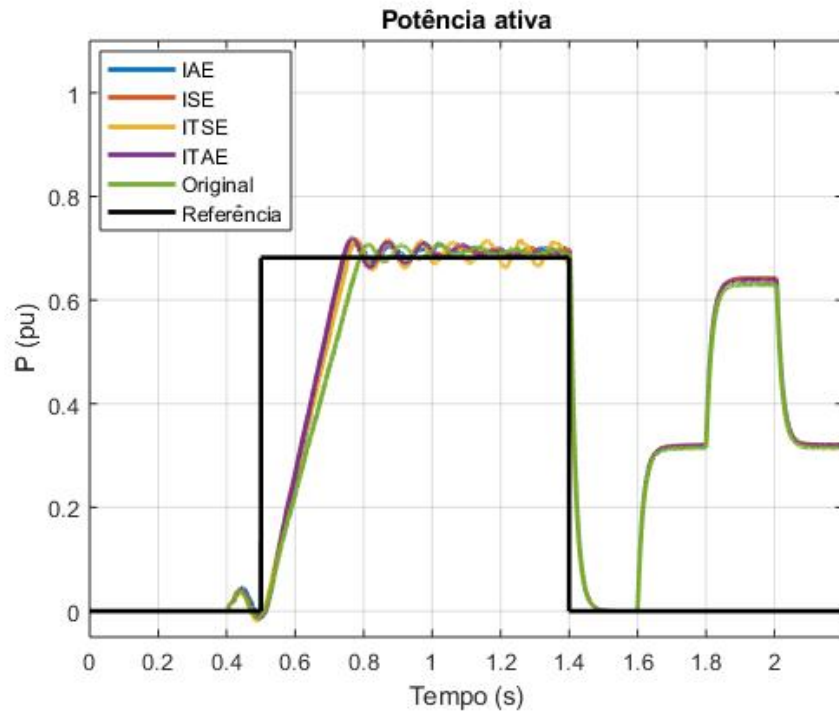
Tabela 6 – Tabela com os ganhos de entrada obtidos após a aplicação do PSO.

PSO				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	428,6572	0,8871	4,7252	1,3569
ISE	404,5781	0,7973	3,7251	1,3772
ITAE	433,8563	0,8343	4,2745	1,4863
ITSE	411,2641	0,8260	2,6912	1,4234

4.2 Resultados - Algoritmos Genéticos


Todas as grandezas que serão apresentadas foram convertidas para o sistema p.u. No caso estudado, em 0,4 segundos a MR conecta-se à RD, em 0,5 segundos a referência de potência ativa é alterada de 0 para 3000 W, em 1 segundo a referência de potência reativa é alterada de 0 para 880 VAr, em 1,4 segundos a MR é desconectada da RD, em 1,6 segundos uma carga é acoplada ao PCC, em 1,8 segundos outra carga é acoplada e em 2 segundos uma das cargas é retirada. Os resultados obtidos para o caso de estudo onde se utiliza o PSO são apresentados abaixo.

Figura 14 – Cenário completo do caso de estudo utilizando o GA - Potência Ativa.



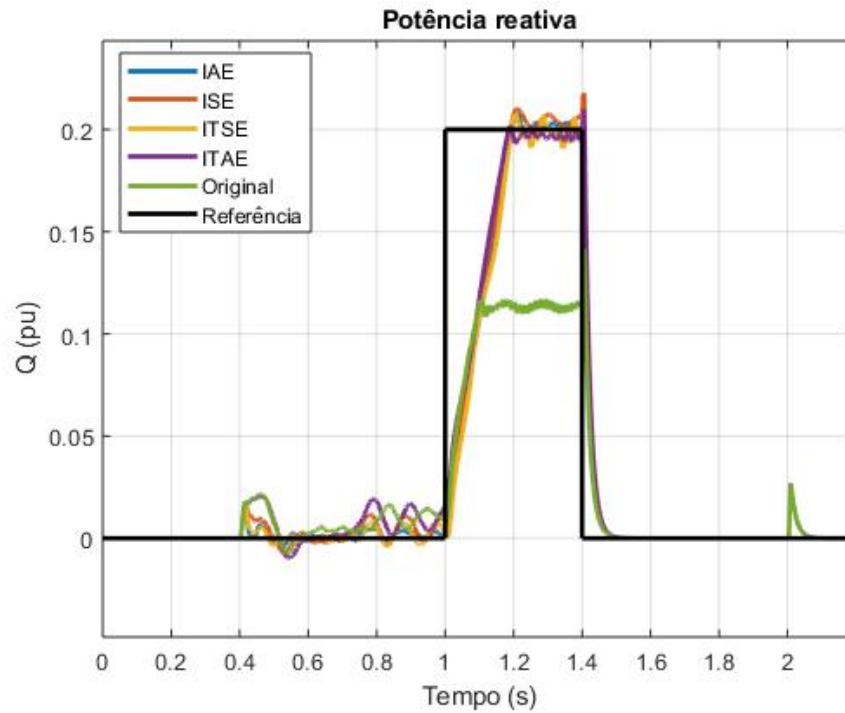
Fonte: Acervo pessoal.

Figura 15 – Cenário completo do caso de estudo utilizando o GA - Frequência.



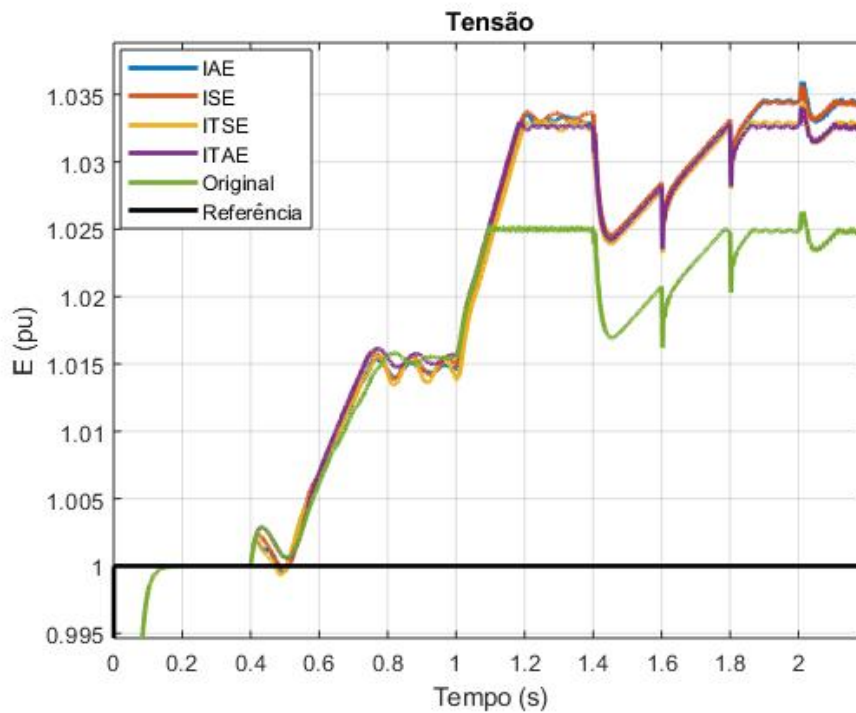
Fonte: Acervo pessoal.

Figura 16 – Cenário completo do caso de estudo utilizando o GA - Potência Reativa.



Fonte: Acervo pessoal.

Figura 17 – Cenário completo do caso de estudo utilizando o GA - Tensão.



Fonte: Acervo pessoal.

No modo conectado, percebe-se que as respostas obtidas após a otimização para a potência ativa e a frequência não apresentaram grandes diferenças em comparação com os valores originais do trabalho de Neves (2018), sendo que as referências foram atingidas para ambos os casos, com pequenas oscilações para a potência ativa. Já as repostas obtidas após a otimização para a potência reativa e a tensão apresentam grandes diferenças quando comparadas aos valores originais do trabalho de Neves (2018). A potencia reativa atingiu sua referência com precisão bem superior após a otimização, já a tensão apresentou maior erro após a otimização.

No caso da MR operando ilha com entrada e saída de cargas, a única variável que apresentou resultados divergentes em comparação com o trabalho original, foi a tensão, sendo que seu erro aumentou após a otimização.

Os valores obtidos para os ganhos de entrada através do GA são apresentados na Tabela 7.

Tabela 7 – Tabela com os ganhos de entrada obtidos após a aplicação do GA.

GA				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	429,7621	0,8661	4,8641	1,4448
ISE	400,8462	0,9625	2,2449	1,4486
ITAE	400,0625	0,8925	1,0174	1,5279
ITSE	442,2534	1,3085	4,5533	1,5151

4.3 Indicador de desempenho

O erro quadrático médio (do ingles MSE) é utilizado a fim de obter um indicador de desempenho para a escolha do melhor resultado após a aplicação das otimizações. São utilizados os erros percentuais de cada variável para o cálculo, conforme apresentado nas equações (4.1), (4.2), (4.3) e (4.4):

$$E_{\omega} = \frac{\omega_{ref} - \omega_{pcc}}{\omega_{ref}}, \quad (4.1)$$

$$E_P = \frac{P_{ref} - P_{MG}}{P_{ref}}, \quad (4.2)$$

$$E_Q = \frac{Q_{ref} - Q_{MG}}{Q_{ref}}, \quad (4.3)$$

$$E_{tensão} = \frac{e_{ref} - e_{pcc}}{e_{ref}}. \quad (4.4)$$

O indicador de desempenho é descrito pela equação (4.5).

$$MSE = \frac{1}{n} \sum_{n=1}^{n=m} (E)^2 \quad (4.5)$$

Onde n é o número de amostras, m é a última amostra, Y_{ref} o valor de referência e Y_n o valor da amostra medida no PCC.

No caso conectado são considerados os seguintes erros: frequência, potência ativa, potência reativa e tensão. No caso ilhado são considerados apenas os erros de frequência e tensão, haja vista, que neste caso deseja-se atender a demanda de cargas locais. A Tabela 8 apresenta os resultados do indicador de desempenho para o PSO, o GA e por fim para os valores originais utilizados no trabalho de Neves (2018).

Tabela 8 – Tabela com os indicadores de desempenho para os casos conectado e ilhado (0,4 a 2,2 segundos).

PSO				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0,0512 (W)^2$	$0,0334 (VAr)^2$	$0,0007 (V)^2$
ISE	$0 (Hz)^2$	$0,0493 (W)^2$	$0,0331 (VAr)^2$	$0,0007 (V)^2$
ITAE	$0 (Hz)^2$	$0,0515 (W)^2$	$0,0331 (VAr)^2$	$0,0007 (V)^2$
ITSE	$0 (Hz)^2$	$0,0497 (W)^2$	$0,0325 (VAr)^2$	$0,0007 (V)^2$
GA				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0,0513 (W)^2$	$0,0335 (VAr)^2$	$0,0007 (V)^2$
ISE	$0 (Hz)^2$	$0,0494 (W)^2$	$0,0318 (VAr)^2$	$0,0007 (V)^2$
ITAE	$0 (Hz)^2$	$0,0499 (W)^2$	$0,0290 (VAr)^2$	$0,0006 (V)^2$
ITSE	$0 (Hz)^2$	$0,0506 (W)^2$	$0,0370 (VAr)^2$	$0,0006 (V)^2$
Ganhos originais				
	Frequência	Potência ativa	Potência reativa	Tensão
	$0 (Hz)^2$	$0,0568 (W)^2$	$0,0583 (VAr)^2$	$0,0004 (V)^2$

Quanto mais próximo de zero, menor o erro entre a referência e os valores medidos. A Tabela 8 apresenta o MSE da simulação considerando tanto a microrrede conectada, quanto ilhada. O destaque em cinza indica qual algoritmo foi aplicado e, por fim são apresentados os valores obtidos para os ganhos originais. A primeira coluna indica qual função de custo foi utilizada para se obter os resultados apresentados. No caso da segunda linha, por exemplo, pode-se entender que o algoritmo utilizado foi o PSO e a função de custo utilizada na otimização foi a IAE (equação (3.2)). A seguir será apresentada a tabela de desempenho somente para o caso conectado (0,4 a 1,4 segundos) e na sequência será apresentada a tabela de desempenho somente para o caso ilhado, após a entrada em regime permanente (1,55 a 2,2 segundos).

Tabela 9 – Tabela com os indicadores de desempenho somente para o caso conectado (0,4 a 1,4 segundos).

PSO				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0,0921 (W)^2$	$0,0601 (VAr)^2$	$0,0004 (V)^2$
ISE	$0 (Hz)^2$	$0,0888 (W)^2$	$0,0596 (VAr)^2$	$0,0004 (V)^2$
ITAE	$0 (Hz)^2$	$0,0927 (W)^2$	$0,0595 (VAr)^2$	$0,0004 (V)^2$
ITSE	$0 (Hz)^2$	$0,0894 (W)^2$	$0,0585 (VAr)^2$	$0,0004 (V)^2$
GA				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0,0923 (W)^2$	$0,0602 (VAr)^2$	$0,0004 (V)^2$
ISE	$0 (Hz)^2$	$0,0889 (W)^2$	$0,0572 (VAr)^2$	$0,0004 (V)^2$
ITAE	$0 (Hz)^2$	$0,0898 (W)^2$	$0,0522 (VAr)^2$	$0,0004 (V)^2$
ITSE	$0 (Hz)^2$	$0,0910 (W)^2$	$0,0666 (VAr)^2$	$0,0004 (V)^2$
Ganhos originais				
	Frequência	Potência ativa	Potência reativa	Tensão
	$0 (Hz)^2$	$0,1023 (W)^2$	$0,1049 (VAr)^2$	$0,0003 (V)^2$

Tabela 10 – Tabela com os indicadores de desempenho somente para o caso ilhado (1,55 a 2,2 segundos).

PSO				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0011 (V)^2$
ISE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0011 (V)^2$
ITAE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0010 (V)^2$
ITSE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0011 (V)^2$
GA				
F. C. utilizada	Frequência	Potência ativa	Potência reativa	Tensão
IAE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0010 (V)^2$
ISE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0010 (V)^2$
ITAE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0009 (V)^2$
ITSE	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0009 (V)^2$
Ganhos originais				
	Frequência	Potência ativa	Potência reativa	Tensão
	$0 (Hz)^2$	$0 (W)^2$	$0 (VAr)^2$	$0,0005 (V)^2$

O padrão de leitura das Tabelas 9 e 10 é o mesmo da Tabela 8. Através da análise de cada modo, pode-se entender melhor o comportamento do CSF e o impacto das otimizações aplicadas. No caso conectado, houve uma melhora de cerca de 50% no controle da potência reativa, considerando o índice utilizado, o controle de potência ativa melhorou cerca de 10% e o controle de tensão piorou cerca de 33%. Já no caso ilhado, a tensão apresentou um aumento do erro em cerca de 50%. Neste caso, a tensão medida no PCC antes do ilhamento continuou a mesma após o ilhamento.

4.4 Discussão

Através da análise dos resultados é possível entender o valor da aplicação dos HOAs e seu funcionamento. Apesar dos resultados encontrados para a tensão nas Seções 4.1 e 4.2 apresentarem uma resposta pior, quando comparado aos valores originais do trabalho de Neves (2018), no caso onde a MR é conectada à RD, observa-se a melhora significativa do controle das potências ativa e reativa obtida pela aplicação das otimizações.

Devido aos acoplamentos entre potência ativa e frequência, assim como entre potência reativa e tensão, para uma linha altamente indutiva, não é possível atingir, simultaneamente, a referência de potência ativa e frequência ou a referência de potência reativa e tensão. Contudo, a aplicação dos HOAs buscou um ponto da função de custo onde o erro fosse mínimo, e o valor encontrado resultou na melhora do controle para a potência reativa, em contrapartida houve uma piora no controle da tensão.

Analisando-se novamente a função de custo generalizada (equação (3.6)), percebe-se que todas as integrais são ponderadas pelo valor 1, isso significa que todas possuem a mesma “importância”. Caso uma variável, por exemplo a tensão, possuísse maior importância que as outras dentro da MR, uma ponderação poderia ser feita para ela, com o objetivo de melhorar sua resposta, a equação (4.6) abaixo exemplifica isso:

$$\mathbf{Função\ de\ custo} = \frac{1}{T} \cdot \left(\int_0^t E_{n\omega} dt + \int_0^t E_{nP} dt + \int_0^t E_{nQ} dt + 10 \int_0^t E_{nv} dt \right) \quad (4.6)$$

Nos casos apresentados, nenhuma variável foi considerada mais importante que a outra, devido a isso e ao acoplamento entre a potência reativa e tensão, o sistema otimizados apresentou melhor resposta para potência reativa e pior resposta para tensão, em comparação com os ganhos originais.

Como o caso estudado envolve uma MR que atua tanto ilhada como conectada à RD, os parâmetros definidos para o controlador fuzzy devem ser tais que, em ambos os modos de conexão, a resposta do controlador deve possuir o menor erro possível. Caso a MR opere apenas conecta ou apenas desconecta da RD, é possível obter ganhos que resultam em melhores respostas do controlador, isso se deve ao fato de no modo ilhado, por exemplo, ser necessária a regulação apenas da tensão e da frequência, já no modo conectado as potências são as variáveis que se deseja controlar, dessa forma, não existiria a preocupação com o acoplamento entre as variáveis, conforme explicado anteriormente.

5 Conclusão

Este trabalho propôs a aplicação do HOAs para obtenção dos parâmetros de fuzificação de um controlador fuzzy aplicado à microrredes CA operando tanto no modo conectado quanto no desconectado. Os resultados obtidos através de uma função de custo que atribui a mesma importância para as variáveis controladas decorreu em uma melhora de exportação de potência ativa e reativa no modo conectado à RD, e uma leve piora no controle de tensão no PCC.

Com os resultados obtidos foi possível entender o comportamento dos HOAs na busca do ponto de ótimo, assim como modelar a função de custo conforme a necessidade do projeto, atribuindo escalas de importância às variáveis analisadas.

Em questão de resultados quantitativos, tanto o PSO, quanto o GA obtiveram o respostas semelhantes. A utilização de diferentes funções de custo também não apresentou nenhuma diferença significativa. Dentre os casos, pode-se destacar que o GA utilizando a função de custo ITAE como o que apresentou o melhor desempenho, pois possui a menor soma de erros.

Em relação ao gasto computacional, o PSO é uma alternativa mais interessante que o GA. Devido a sua fácil implementação e simplicidade de cálculos o esforço computacional torne-se menor quando comparado ao GA.

O estudo de caso proposto levou em consideração uma MR atuando tanto conectada quanto desconectada da RD, devido ao acoplamento das variáveis da MR um meio termo entre os dois modos foi atingido. Uma possível continuação deste trabalho pode se realizada buscando identificar qual o desempenho da otimização para a MR somente conectada ou desconectada. Além disso, futuros trabalhos também podem trabalhar em alterações no CSF para que a tensão medida antes e após um ilhamento não sejam as mesmas, conforme as análises feitas para a Tabela 10.

Referências

- ABRAHAM, A.; DAS, S. *Computational intelligence in power engineering*. [S.l.]: Springer, 2010. v. 302. Citado na página 22.
- AGNOLETTO, E. J. *Sistema de gerenciamento ótimo de energia em microrredes CA baseado em fluxo de potência e correntes harmônicas*. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2020. Citado na página 11.
- AHMADI, S.; SHOKOOHI, S.; BEVRANI, H. A fuzzy logic-based droop control for simultaneous voltage and frequency regulation in an ac microgrid. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 64, p. 148–155, 2015. Citado na página 12.
- ANTUNES, A. P.; AZEVEDO, J. L. F. Studies in aerodynamic optimization based on genetic algorithms. *Journal of Aircraft*, American Institute of Aeronautics and Astronautics, v. 51, n. 3, p. 1002–1012, 2014. Citado na página 12.
- BALAMURUGAN, K.; SRINIVASAN, D. Review of power flow studies on distribution network with distributed generation. In: IEEE. *2011 IEEE Ninth International Conference on Power Electronics and Drive Systems*. [S.l.], 2011. p. 411–417. Citado na página 11.
- BIDRAM, A.; LEWIS, F. L.; DAVOUDI, A. Distributed control systems for small-scale power networks: Using multiagent cooperative control theory. *IEEE Control systems magazine*, IEEE, v. 34, n. 6, p. 56–77, 2014. Citado 2 vezes nas páginas 11 e 14.
- BURKE, E. K. et al. *Search methodologies: introductory tutorials in optimization and decision support techniques*. [S.l.]: Springer, 2014. Citado na página 13.
- DELIVERY, D. of Energy Office of E.; RELIABILITY, E. *Summary Report: 2012 DOE Microgrid Workshop*. 2012. Último acesso 16 de Outubro de 2021. Disponível em: <<https://www.energy.gov/sites/prod/files/2012%20Microgrid%20Workshop%20Report%2009102012.pdf>>. Citado na página 11.
- EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: IEEE. *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. [S.l.], 1995. p. 39–43. Citado na página 19.
- EBRAHIM, M. et al. Optimal pi based secondary control for autonomous micro-grid via particle swarm optimization technique. In: IEEE. *2018 Twentieth International Middle East Power Systems Conference (MEPCON)*. [S.l.], 2018. p. 1148–1155. Citado na página 22.
- GA. *Genetic Algorithms*. 2019. Último acesso 09 de Abril de 2022. Disponível em: <<https://www.mathworks.com/help/gads/ga.html#d123e48533>>. Citado na página 24.
- GUERRERO, J. M. et al. Advanced control architectures for intelligent microgrids—part i: Decentralized and hierarchical control. *IEEE Transactions on Industrial Electronics*, IEEE, v. 60, n. 4, p. 1254–1262, 2012. Citado 2 vezes nas páginas 14 e 15.

- GUERRERO, J. M. et al. Hierarchical control of droop-controlled ac and dc microgrids—a general approach toward standardization. *IEEE Transactions on industrial electronics*, IEEE, v. 58, n. 1, p. 158–172, 2010. Citado na página 16.
- HOLLAND, J. H. et al. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. [S.l.]: MIT press, 1975. Citado na página 18.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95-international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948. Citado na página 19.
- LI, C. et al. Power flow analysis algorithm for islanded lv microgrids including distributed generator units with droop control and virtual impedance loop. In: IEEE. *2014 IEEE Applied Power Electronics Conference and Exposition-APEC 2014*. [S.l.], 2014. p. 3181–3185. Citado na página 11.
- LU, X. et al. Hierarchical control of parallel ac-dc converter interfaces for hybrid microgrids. *IEEE Transactions on Smart Grid*, IEEE, v. 5, n. 2, p. 683–692, 2013. Citado na página 11.
- NEVES, R. V. A. *Controlador secundário fuzzy multitarefa aplicado à operação autônoma de microrredes CA*. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2018. Citado 14 vezes nas páginas 7, 12, 13, 15, 16, 17, 18, 23, 24, 25, 30, 33, 34 e 36.
- NIU, M.; WAN, C.; XU, Z. A review on applications of heuristic optimization algorithms for optimal power flow in modern power systems. *Journal of Modern Power Systems and Clean Energy*, SGEPRI, v. 2, n. 4, p. 289–297, 2014. Citado na página 12.
- PARHIZI, S. et al. State of the art in research on microgrids: A review. *Ieee Access*, IEEE, v. 3, p. 890–925, 2015. Citado na página 11.
- PARTICLESWARM. *Particle swarm optimization*. 2014. Último acesso 09 de Abril de 2022. Disponível em: <<https://www.mathworks.com/help/gads/particleswarm.html#budidgf-options>>. Citado na página 24.
- PATRAO, I. et al. Microgrid architectures for low voltage distributed generation. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 43, p. 415–424, 2015. Citado na página 11.
- ROCABERT, J. et al. Control of power converters in ac microgrids. *IEEE transactions on power electronics*, IEEE, v. 27, n. 11, p. 4734–4749, 2012. Citado na página 11.
- SHAN, Y. et al. A unified model predictive voltage and current control for microgrids with distributed fuzzy cooperative secondary control. *IEEE Transactions on Industrial Informatics*, IEEE, 2021. Citado na página 22.
- SINDHIYA, S.; GUNASUNDARI, S. A survey on genetic algorithm based feature selection for disease diagnosis system. In: IEEE. *Proceedings of IEEE international conference on computer communication and systems ICCCS14*. [S.l.], 2014. p. 164–169. Citado na página 12.

WOLPERT, D.; MACREADY, W. No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, v. 1, n. 1, p. 67–82, 1997. Citado na página 25.

ZHANG, Y.; WANG, S.; JI, G. A comprehensive survey on particle swarm optimization algorithm and its applications. *Mathematical problems in engineering*, Hindawi, v. 2015, 2015. Citado na página 12.