

Allocation and Sizing of Photovoltaic Systems to Reduce Power Losses and Economic Aspects using a New PSO Approach

Alex F. Moreira and Yuri P. Molina and Zocimo Ñaupari and Ronaldo R. Aquino

Abstract—In this paper is proposed a new method for optimal allocation and sizing of Photovoltaics (PVs) systems in power distribution network to reduce losses in feeders and minimize the economic aspects of the PVs implementation. The proposed technique, called Modified Particle Swarm Optimization with Dynamic Momentum (MPSO-DM) is proposed so that can be applied in distribution system, that requires a high number of decision variables in the optimization process. This becomes necessary because the classical Particle Swarm Optimization (PSO), in general, presents a performance drop in the exploration of the search space when applied to these situations. The proposed method was tested in a real distribution network of the Federal University of Paraíba (79 buses), which results show a improvement in performance, yielding better solutions when compared to the traditional Modified Particle Swarm Optimization (MPSO) method and MPSO with linear decrement inertia weight.

Index Terms—Optimal size and location, Dynamic Momentum, Adapted MPSO, Loss minimization, Cost minimization.

I. INTRODUÇÃO

A energia solar fotovoltaica como fonte alternativa de produção de energia pode se tornar uma solução para o futuro crescimento da demanda energética, uma vez que em escala global o consumo de eletricidade tende a aumentar nos próximos anos, levando à necessidade urgente de desenvolver novas formas de geração de energia para atender a demanda prevista [1]. Além de serem classificados dentro do conceito de Geração Distribuída (GD), os sistemas fotovoltaicos (SFs) apresentam baixo custo de geração em comparação a geração centralizada, são independentes das linhas de transmissão e são também uma fonte de energia renovável, o que contribui diretamente para a redução dos impactos ambientais [2].

A instalação dessas fontes de GD podem trazer benefícios ao sistema ao qual está conectada, tal como a redução de perdas nos alimentadores da rede. Entretanto, o dimensionamento de geração e definição da localização dessas unidades geradoras devem levar em consideração os aspectos técnicos, pois, uma proposição não otimizada pode aumentar as perdas por efeito joule nos alimentadores da rede e/ou ainda elevar o custo

de investimento. É necessário verificar se os barramentos escolhidos para instalação dos SFs, bem como suas potências dimensionadas, irão proporcionar uma redução efetiva de perdas nos alimentadores da rede, e se essa solução apresenta um menor custo de investimento [3], [4].

Diferentes técnicas e métodos são usados na alocação e dimensionamento ótimo de GD em sistemas de distribuição [5]–[8]. Os métodos citados incluem técnicas clássicas de otimização, inteligência artificial (meta-heurísticas) e técnicas híbridas. Métodos de otimização com inteligência artificial (IA) têm sido amplamente utilizados nos últimos anos e são considerados métodos de otimização modernos. A maioria desses métodos de otimização é baseada nas características biológicas, comportamentais, neurobiológicas e de inteligência de enxames [4], [9].

Inicialmente introduzido por Kennedy e Eberhart em 1995 [10], a otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) é um método de otimização bio-inspirado e apresenta-se como uma ótima ferramenta para otimizar o planejamento da alocação e dimensionamento de GDs em sistemas de distribuição para reduzir perdas e, conseqüentemente, melhorar o perfil de tensão [11]–[14].

Em [4], PSO e Algoritmo Genético (GA) foram usados para reduzir as perdas de energia e melhorar o perfil de tensão. Este trabalho considera uma rede de distribuição da Ilha Masirah (126 barras) onde 5 barras fixas são usadas para o dimensionamento fotovoltaico. Em [15], o PSO foi utilizado para a alocação e dimensionamento de SFs em uma rede de distribuição radial com 26 barramentos. Neste trabalho, unidades fotovoltaicas são instaladas em todos os barramentos, o que por consequência acarreta em custos elevados, uma análise de custo-benefício da implantação dos SFs mostra-se conveniente nesta aplicação. Em [16], foi usado o PSO com um peso de inércia linearmente decrescente para dimensionamento e alocação de geração distribuída para reduzir perdas de energia e melhorar a confiabilidade do sistema. A aplicação proposta utiliza um sistema de distribuição com 12 barras, entretanto, apenas 4 barras estão disponíveis como variáveis de otimização. Em [17], o PSO foi usado para alocação e dimensionamento de GD para minimizar perdas de energia, melhorar o perfil de tensão e reduzir níveis de distorção harmônico na rede de distribuição. A aplicação proposta utiliza um sistema de distribuição com 12 barras, no entanto, apenas 2 barramentos são usados para inserção de GD.

Embora esses trabalhos citados encontrem suas respectivas soluções ótimas, eles utilizam poucas variáveis de decisão,

Essa pesquisa foi financiada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

Alex F. F. Moreira é estudante de pós-graduação, nível doutorado, da Universidade Federal de Pernambuco - Brasil e-mail:alex.ferreiram@ufpe.br.

Yuri P. Molina é professor da Universidade Federal da Paraíba - Brasil e-mail:molina.rodriguez@cear.ufpb.br

Zocimo Ñaupari é professor da Universidad Nacional de Ingeniería - Peru e-mail:znaupari@uni.edu.pe

Ronaldo R. Aquino é professor da Universidade Federal de Pernambuco - Brasil e-mail:rrba@ufpe.br

ou seja, poucas possibilidades de barramentos disponíveis para otimização, estes, são caracterizados como sistemas de pequena dimensão. Em sistemas de grandes dimensões, ou seja, com muitas variáveis de decisão a otimização pode não ocorrer adequadamente. Isso ocorre porque muitos métodos de otimização sofrem da "maldição da dimensionalidade", o que significa que o desempenho destes se deteriora à medida que a dimensionalidade do problema aumenta.

Com o PSO não ocorre diferente, ele enfrenta dificuldades em explorar o espaço de busca quando aplicado em problemas de grandes dimensões [18]. Isso se deve pois as atualizações das dimensões de cada partícula são feitas individualmente e, nos estágios finais de convergência, o número de iterações que buscam uma melhoria geral da função objetivo torna-se baixo, aumentando a probabilidade do enxame convergir para um ótimo local antes mesmo de explorar amplamente o espaço de busca. Com as dimensões das partículas operando independentes, a convergência do enxame de partículas não ocorre simultaneamente em todas as dimensões. Com isso há uma restrição do espaço de busca, pois, as dimensões que convergem precocemente não mais se alteram, limitando a exploração do enxame de partículas [19].

Dessa forma, o objetivo deste trabalho é desenvolver uma nova abordagem do PSO, que utiliza o Modified Particle Swarm Optimization (MPSO) [14] e o Momento Dinâmico [19] para alocação e dimensionamento de SFs em redes de distribuição de energia. As principais contribuições desse trabalho são:

- Adaptação do Momento Dinâmico [19], para operar em conjunto com o MPSO [14];
- Promover, com a aplicação do momento dinâmico, uma maior exploração do espaço de busca, para que melhores soluções sejam encontradas;
- Consideração dos aspectos econômicos na função objetivo, para viabilizar a análise técnica e econômica da inserção dos SFs na rede.

A utilização do momento dinâmico introduz variações na equação de velocidade no enxame de partículas. Tais variações estão diretamente relacionadas à exploração do espaço de busca. O desempenho do método proposto é comparado com outras duas variações do peso de inércia muito empregadas na literatura: decremento linear [20] e peso de inércia tradicional [21].

Este artigo está organizado da seguinte forma: a seção II apresenta uma breve introdução e a modelagem do algoritmo utilizado; A seção III apresenta a aplicação do método proposto na alocação e dimensionamento dos SFs, bem como os requisitos mínimos a serem atendidos pelo algoritmo; na seção IV resultados numéricos ilustrativos são apresentados e discutidos. Conclusão e considerações finais são apresentadas na seção V.

II. OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

O PSO é uma técnica de computação evolutiva, baseada em mecanismos biológicos que visa resolver problemas de otimização implementados em um computador. O algoritmo é baseado no comportamento de algumas espécies de aves

em busca de alimento. A operação do algoritmo começa com um conjunto aleatório de soluções possíveis para o problema proposto que são atualizadas através de um processo iterativo até que converta para um resultado ideal.

A. Otimização do Enxame de Partículas Modificado - MPSO

O método MPSO tradicional [14] é uma variação do método PSO clássico [10], modificado para otimizar usando valores inteiros, o que o torna muito atraente no projeto de SFs em redes de distribuição visto que os módulos comerciais apresentam valores padronizados de potência inteiros.

O processo de atualização da partícula é feito em duas etapas, dadas por (1) e (2).

$$v_{id}^{t+1} = \omega v_{id}^t + \phi_1 rand_1 (Pbest_{id}^t - x_{id}^t) + \phi_2 rand_2 (Gbest_d^t - x_{id}^t) \quad (1)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (2)$$

No quais os parâmetros são descritos na Tabela I.

TABELA I
PARÂMETROS DAS EQUAÇÕES (1) E (2).

Parâmetro	Descrição
ω	Peso de inércia.
i	Índice da partícula.
t	Índice de tempo discreto.
v_{id}^t	Velocidade da partícula i na dimensão d no instante de tempo t .
x_{id}^t	Posição da partícula i na dimensão d no instante de tempo t .
ϕ_1	Parâmetro cognitivo.
ϕ_2	Parâmetro social.
$rand$	Número gerado aleatoriamente entre 0 e 1 aplicado na n^{th} partícula.
$Pbest_{id}^t$	Melhor posição da partícula i na dimensão d no instante de tempo t .
$Gbest_d^t$	Melhor posição da população do enxame na dimensão d no instante de tempo t .

A Figura 1 ilustra a configuração de i partículas com d dimensões.

		dimensão				
		1	2	...	(d-1)	d
partículas	1	\mathcal{V}_{11} \mathcal{X}_{11}	\mathcal{V}_{12} \mathcal{X}_{12}	...	$\mathcal{V}_{1(d-1)}$ $\mathcal{X}_{1(d-1)}$	\mathcal{V}_{1d} \mathcal{X}_{1d}
	⋮			⋮		
	(i-1)	$\mathcal{V}_{(i-1)1}$ $\mathcal{X}_{(i-1)1}$	$\mathcal{V}_{(i-1)2}$ $\mathcal{X}_{(i-1)2}$...	$\mathcal{V}_{(i-1)(d-1)}$ $\mathcal{X}_{(i-1)(d-1)}$	$\mathcal{V}_{(i-1)d}$ $\mathcal{X}_{(i-1)d}$
	i	\mathcal{V}_{i1} \mathcal{X}_{i1}	\mathcal{V}_{i2} \mathcal{X}_{i2}	...	$\mathcal{V}_{i(d-1)}$ $\mathcal{X}_{i(d-1)}$	\mathcal{V}_{id} \mathcal{X}_{id}

Fig. 1. Configuração das partículas no MPSO.

A inovação do MPSO em relação ao PSO clássico é implementada após o cálculo de (2), se x_{id}^{t+1} assume um valor real ($x_{id}^{t+\frac{1}{2}}$), seu valor é truncado para o número discreto mais próximo.

B. Peso de Inércia ω

O peso de inércia desempenha um papel fundamental nas técnicas que utilizam o PSO, ele afeta significativamente a convergência e exploração do algoritmo na busca do valor ótimo. O peso de inércia determina a taxa de contribuição da velocidade anterior de uma partícula para atualizar sua velocidade no momento atual. O conceito de peso inercial foi introduzido pela primeira vez em 1998 por Shi e Eberhart [21]. Eles afirmaram que um grande peso de inércia facilita uma busca global, enquanto um pequeno facilita uma busca local.

A fim de melhorar o desempenho do PSO, diversos métodos são utilizados para calcular o ω , visando a melhoria do desempenho do algoritmo [22], [23]. Em [20] uma estratégia de decremento linear é proposta. Os resultados mostram que variando linearmente o ω de 0,9 a 0,4 resultados satisfatórios são obtidos quanto à eficiência e desempenho do algoritmo.

Apesar das várias técnicas e modificações feitas no PSO e seus variantes, o desempenho do algoritmo pode cair com o aumento da dimensão, ainda sim, geralmente os algoritmos convergem para um valor ótimo no espaço de busca, mas dificilmente para um ótimo global. Para contornar este problema, em [19] é proposto o uso do momento dinâmico, este substitui o peso de inércia na equação (1). Esta técnica tem melhor desempenho quando aplicada em problemas de alta dimensão, ou seja, quando $d \geq 30$, de acordo com [19].

Este trabalho, portanto, tem como objetivo adaptar o método do momento dinâmico para aplicá-lo no MPSO, resultando no MPSO-MD. Esta nova técnica permite um melhor desempenho na alocação e dimensionamento ótimo de SFs em redes de distribuição com alta dimensão, ou seja, quando se deseja realizar uma otimização com um grande número de variáveis de decisão.

C. MPSO com Momento Dinâmico - MPSO-MD

O momento dinâmico [19] funciona de forma que as atualizações nas dimensões não sejam realizadas individualmente como ocorre no PSO clássico, dessa forma, o comportamento do enxame de partículas pode ser modificado de modo que as dimensões das partículas convirjam todas juntas. Como resultado, o enxame de partículas geralmente irá explorar mais o espaço de busca e convergir para uma melhor solução.

No método do momento dinâmico, um intervalo de tempo é aplicado para atualizar a velocidade e posição das partículas, que divide os componentes dos parâmetros cognitivos e sociais (equação (1) em [19]). Assim, as velocidades tendem a diminuir com as atualizações das iterações, até que seus valores tendam a zero. Porém, no MPSO-MD a variável tempo não é considerada, pois o algoritmo desenvolvido é projetado para otimizar utilizando passos discretizados e não é "temporizado continuamente".

Para determinar o momento, é necessário calcular a velocidade média absoluta (V_d^{av}) e a velocidade média (S_d^{av}). A velocidade média absoluta é calculada considerando o sinal das velocidades das partículas, já a velocidade média é calculada pelo módulo das velocidades, pois $s_i = abs(v_i)$. As equações

da velocidade absoluta média e da velocidade média são calculadas em (3) e (4) respectivamente [19].

$$V_d^{av} = abs\left(\frac{1}{N} \times \sum_{i=1}^N v_i\right) \tag{3}$$

$$S_d^{av} = \frac{1}{N} \times \sum_{i=1}^N s_i \tag{4}$$

Os parâmetros v_i , s_i e N são, respectivamente, a velocidade da partícula i na dimensão d , a velocidade absoluta da partícula i na dimensão d e o número de partículas adotado. Ao fazer uma análise detalhada de (3) e (4), observa-se que a velocidade média (plotada horizontalmente na Figura 2) nunca será maior que a velocidade média absoluta (plotada verticalmente na Figura 2), de forma que o ponto "Enxame" nunca aparecerá no topo direito (hachurado).

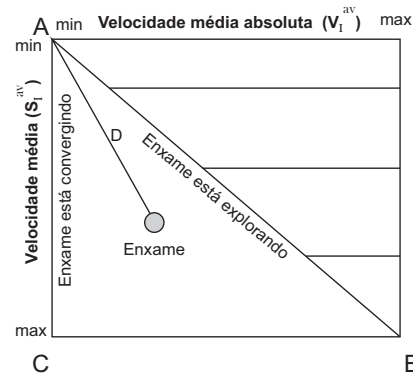


Fig. 2. Distância de uma dimensão à convergência. Adaptado de [19].

Com a velocidade média e a velocidade média absoluta, calcula-se a distância do enxame de partículas para a convergência na dimensão d dada por (5).

$$D_d = \sqrt{(V_d^{av})^2 + (S_d^{av})^2} \tag{5}$$

Esta magnitude quantifica as variações de velocidade de um enxame na dimensão d . Tais variações estão diretamente relacionadas com a exploração do espaço de busca, de forma que se as variações forem grandes significa que há uma maior exploração no espaço de busca, se forem pequenas a exploração é menor.

Quanto mais próximo o ponto "Enxame" estiver da linha AC ($V_d^{av} \rightarrow 0$) menor será a variação da velocidade nessa dimensão d , e as partículas devem estar circulando em algum ponto, presumivelmente convergindo. Quanto mais próximo o ponto "Enxame" estiver da linha AB ($V_d^{av} \rightarrow max$), maiores serão as variações de velocidade, então as partículas devem explorar o espaço de busca. É importante notar que existe um gráfico semelhante à Figura 2 para cada dimensão da partícula, e essas figuras podem apresentar características diferentes nas respectivas dimensões.

A ideia de calcular a distância de convergência é mapear as dimensões que estão prestes a convergir. A essas dimensões aplica-se um ajuste (momento dinâmico), para que elas possam explorar mais o espaço de busca antes de convergir precocemente. Para calcular o momento dinâmico calcula-se o peso do momento, W_d , dado por (6).

$$W_d = \frac{D^{max}}{D^{max} + D_d} \quad (6)$$

Em que os parâmetros W_d , D^{max} e D_d são, respectivamente, peso do momento na dimensão d , distância máxima para convergência entre todas as dimensões e distância do enxame para convergência na dimensão d .

O W_d é uma variável que leva em consideração todas as dimensões do problema. Assim, mesmo que uma dimensão específica esteja próxima de convergir, ela será afetada pela dimensão que está mais longe da convergência (D^{max}), evitando que uma dimensão específica recaia sobre um ótimo local. Portanto, o peso variável do momento ajuda todas as partículas a explorar o espaço de busca até que todas as partículas converjam juntas. O peso do momento é aplicado posteriormente para encontrar o momento M_d como mostrado em (7).

$$M_d = \left(\frac{N_g \times W_d}{\sum_{j=1}^{N_g} W_j} \right)^{pwr} \quad (7)$$

Para entender o momento M_d é necessário interpretar a equação (6) mais profundamente. Observa-se que o menor valor W_d calculado ocorre quando $D_d = D^{max}$. Por outro lado, quanto menor o D_d , maior o W_d . Com essas informações é possível entender (7) mais claramente, ao observar que o único termo variável nesta equação é W_d , presente no numerador da equação, e que quanto menor a distância D_d , maior será o W_d calculado, e também o M_d . Isso garante que a dimensão que está perto da convergência ($D_d \rightarrow 0$) saia de sua "zona de conforto" e explore mais o espaço de busca até que todas as dimensões e por consequência, todas as partículas, converjam juntas.

Finalmente, o momento M_d^{aPP} é calculado usando a equação (8). A introdução do fator F nessa equação permite ponderar o peso de M_d e o peso do momento dinâmico da iteração anterior (M_d^{last}). Ponderar com um $F \rightarrow 1$ fará com que o M_d^{aPP} seja mais conservador, variando pouco a cada iteração. Quando $F \rightarrow 0$ fará com que o M_d^{aPP} varie de forma abrupta. Idealmente deve-se trabalhar com $F \approx 0,5$, assim como na referência [19].

$$M_d^{aPP} = (1 - F) \times M_d + F \times M_d^{last} \quad (8)$$

Os parâmetros usados em (7) e (8) são definidos na Tabela II. A equação de velocidade no MPSO-DM torna-se:

$$v_{id}^{t+1} = M_d^{aPP} v_{id}^t + \phi_1 rand_1 (Pbest_{id}^t - x_{id}^t) + \phi_2 rand_2 (Gbest_d^t - x_{id}^t) \quad (9)$$

A atualização da posição da partícula no MPSO-DM ocorre aplicando a equação (2).

D. Etapas do MPSO-MD Proposto

Para aplicar o MPSO-MD as 11 etapas seguintes precisarão ser cumpridas:

1. O cálculo do fluxo de carga sem SFs é necessário para estimar a operação da rede, em regime permanente. Os perfis de tensão e carregamento do alimentador nos ramais do sistema são obtidos nessa etapa.

TABELA II
PARÂMETROS DAS EQUAÇÕES (7) E (8)

Parâmetro	Descrição
M_d	Momento na dimensão d calculado por (7).
N_g	Números de dimensões.
pwr	Expoente do momento
ϕ_1	Parâmetro cognitivo.
ϕ_2	Parâmetro social.
M_d^{aPP}	Momento aplicado como peso de inércia, substituindo ω em (9).
F	Fator ponderante
M_d^{last}	Momento aplicado na última iteração

2. As potências dos SF e velocidades das partículas são criadas aleatoriamente, cujos valores atribuídos às partículas são valores inteiros em consonância com valores comerciais dos SFs.
3. O fluxo de carga após a inserção dos SFs é calculado. Nessa etapa obtêm-se os parâmetros de rede necessários ao cálculo da função objetivo (FO).
4. A FO é calculada.
5. Nessa etapa salvam-se o P_{best} e G_{best} obtidos na etapa 4.
6. Calcula-se o momento dinâmico M_d^{aPP} .
7. Nesta etapa atualiza-se velocidades das partículas conforme equação (9).
8. As potências dos SFs das partículas são atualizadas.
9. As potências dos SFs são substituídas pelos valores atualizados e o fluxo de carga calculado. Então a função objetivo associada a cada partícula é novamente calculada.
10. No passo (10), as FO anteriores e novas de cada partícula são comparadas. Sempre que a nova Função Objetivo for inferior antiga, o P_{best} é atualizado. Sempre que a FO for a menor de todas encontradas até o momento, G_{best} é atualizado.
11. Finalmente, o critério de parada é verificado na etapa 11. Existem dois requisitos de parada (i) quando o número de iterações (atualização de populações) é igual a 200 ou (ii) até que a diferença entre a pior e melhor Função Objetivo da população seja menor que 1% através do erro calculado pela equação (10), onde F_{worse} e F_{best} , respectivamente, representam a pior e a melhor partícula da população do enxame. Isso implica que o algoritmo convergirá quando todas as partículas do enxame tiverem aproximadamente a mesma FO. Se o critério de parada for atendido, o programa pára a execução e salva os resultados obtidos. Caso não satisfaça o critério de parada, o programa retorna para a etapa 6 e repete o todo o processo até que a etapa 11 seja satisfeita.

$$erro = \left| \frac{F_{worse} - F_{best}}{F_{best}} \right| \times 100\% \quad (10)$$

III. APLICAÇÃO DO MPSO-DM NA ALOCAÇÃO E DIMENSIONAMENTO DE SFs

Para a implementação do método proposto, o PowerFactory[®] foi utilizado em conjunto com sua ferramenta de programação DigSILENT Programming Language (DPL). Os sistemas

fotovoltaicos são então inseridos em todos os barramentos da rede com potência de geração inicial de 0 W. Nesse artigo, cada ponto de subestação aérea, onde há um transformador instalado, foi considerado como um barramento e o método de fluxo de carga utilizado foi Newton-Raphson.

O sistema de distribuição da Universidade Federal da Paraíba é alimentado na tensão nominal de 13,8 kV, composto por 79 transformadores abaixadores de 13,8kV/380V/220V que alimentam diversas instalações do campus, com potência total instalada de 10.080 kVA. Mais informações sobre a rede de distribuição podem ser obtidas em [24].

No desenvolvimento do algoritmo proposto, foram determinadas algumas premissas e restrições a serem consideradas na otimização.

- Premissas:

- 1) As potências disponíveis para dimensionamento de SFs são padronizadas em 0 kW, 20 kW, 40 kW, 60 kW, 80 kW, 100 kW e 120 kW. Essas potências foram definidas com base na potência de carga instalada na rede;
- 2) O número de partículas i foi definido como 100, esta escolha foi baseada no tamanho da extensão do sistema;
- 3) Como medida de segurança, o número máximo de iterações é 200, de forma a evitar que o algoritmo rode ininterruptamente;
- 4) O cenário de simulação adotado considerou a máxima demanda da rede, ou seja, em carga total.

- Restrições:

- 1) Os limites de tensão no barramento k após o dimensionamento devem estar entre $0.95 \leq V_k \leq 1.05$ p.u.;
- 2) O carregamento do alimentador deve ser menor que 100%;
- 3) A potência do SF a ser dimensionada no barramento não deve exceder a potência nominal do transformador.

A. A Função Objetivo

A FO a ser minimizada é composta pelas perdas de potência ativa (kW) e pelos custos de investimento da instalação dos SFs, conforme (11). É portanto, uma função multiobjetivo, pois existem dois objetivos conflitantes a serem otimizados simultaneamente. Assim, minimizar custos implica no aumento das perdas da rede, da mesma forma, a minimização das perdas implica no aumento dos custos envolvidos na instalação dos módulos fotovoltaicos.

$$FO = P_N + Cost \quad (11)$$

P_N representa a soma das perdas nos alimentadores da rede após a inserção dos SFs.

$Cost$, em (11) é composto pelo custo de investimento de (C_i) que depende da potência instalada, subtraído da economia em reais (E_d) que a inserção de SFs proporciona na redução da demanda de energia contratada, como pode ser visto em (12). Portanto, o algoritmo deve reduzir ao máximo as perdas, com baixo custo de investimento e maximizar a economia.

$$FO = P_N + (C_i - E_d) \quad (12)$$

O termo E_d em (12) é composto pela perda (P_A) anterior à instalação dos SFs, subtraída da nova perda (P_N) multiplicada pelo custo unitário da demanda ($R\$/kW$) cobrado pela concessionária local conforme demonstrado em (13).

$$FO = P_N + C_i - (P_A - P_N) \times R\$/kW \quad (13)$$

O termo $-P_A \times R\$/kW$ pode ser desconsiderado por ter valor constante e estar presente em todas as partículas, portanto sua eliminação na FO não implica em nenhum impacto relevante nos resultados otimizados. Para que os termos da FO tenham as mesmas unidades foi necessário multiplicar o primeiro termo P_N da equação (13) pelo custo unitário da demanda, de forma que toda a FO tivesse suas unidades dadas em $R\%$ como pode ser observado em (14).

$$FO = 2 \times P_N \times R\$/kW + C_i + (\Delta V_P + \Delta L_P) \quad (14)$$

Além disso, dois fatores de penalidade ΔV_P e ΔL_P , foram introduzidos em (14), esses são os fatores de penalidade para desvio de tensão e desvio de carregamento dos alimentadores, respectivamente. Esses fatores são necessários para cumprir as restrições 1) e 2) da otimização. Os fatores de penalidade foram empregados para que a alocação e dimensionamento dos SFs nos barramentos possam manter os níveis de tensão entre 0,95 e 1,05 p.u e manter o carregamento dos alimentadores abaixo de 100%. Estando fora desse critério, o fator de penalidade deve ser aplicado à FO dessa partícula. Os fatores de penalidade para os desvios de tensão e carregamento nos alimentadores são dados respectivamente por (15) e (16).

$$\Delta V_P = FP_V \left(\sum_{i=1}^N \Delta V \right) \quad (15)$$

Em que N é o número de barramentos da rede e ΔV é o desvio de tensão verificado nos barramentos, dado por ($\Delta V = 0,95 - V_i$) quando a tensão no barramento i , V_i , está abaixo de 0,95 p.u, ou ($\Delta V = V_i - 1,05$) quando a tensão é maior que 1,05 p.u. Para casos em que V_i está dentro da faixa de tensão desejada, $\Delta V = 0$. $FP_V = 100000$ é a constante de penalidade dos desvios de tensão.

Da mesma forma acontece quando o carregamento de qualquer um dos alimentadores excede 100% de sua capacidade nominal. O desvio de carregamento ΔL é dado por ($\Delta L = D_i - 100$), em que M é o número de alimentadores da rede, D_i representa o carregamento do alimentador i em % e $FP_L = 1000$ é a constante de penalidade dos desvios de carregamento. Para casos em que $D_i \leq 100\%$, $\Delta L = 0$.

$$\Delta L_P = FP_L \left(\sum_{i=1}^M \Delta L \right) \quad (16)$$

É importante destacar o papel das penalidades, pois fazem com que o algoritmo "fuja" das partículas que levaram o sistema de distribuição a violar as restrições exigidas, elevando o valor da FO no caso de violação. Os valores adotados para as constantes de penalidade são justificados pelo fato de o desvio de tensão ser dado em p.u, enquanto o carregamento em %. Dessa forma, com esses fatores adotados, os desvios

de tensão e carregamento passam a ter a mesma ordem de grandeza na FO.

O custo de investimento por *Watt* dos SFs instalados foi adotado como 6,3 R\$/W de acordo com os dados obtidos em [25]; para quantificar as perdas, o custo unitário da demanda contratada foi de 18,92 R\$/kW, com base no valor da concessionária local no estado da Paraíba, Brasil.

Na realização dos cálculos relativos à função objetivo pôde-se verificar que suas parcelas têm valores desproporcionais, as perdas são da ordem de milhares e os custos da ordem de milhões. Esse fato causa um problema para o algoritmo desenvolvido, uma vez que as parcelas da FO teriam ordens de grandezas diferentes. Como consequência, as perdas se tornariam uma componente desprezível na FO, e o algoritmo priorizaria apenas a redução dos custos de investimento. Portanto, foi necessário usar fatores de ponderação $F_{PI} = 184$ e $F_{PC} = 0,5$ multiplicando respectivamente a componente perdas e custos da FO. Esses fatores são obtidos através do valor médio da perda máxima na rede e do valor médio do custo máximo da implantação dos SFs. Com isso, é possível estimar F_{PI} e F_{PC} , que quando aplicados na equação (17) tornam as parcelas perdas e custos com mesma ordem de grandeza.

$$FO = F_{PI} \times P_N \times R\$/kW + F_{PC} \times C_i + (\Delta V_P + \Delta L_P) \quad (17)$$

Os valores ϕ_1 e ϕ_2 adotados para realizar os cálculos em (9) foram respectivamente 1,7 e 1,7. Com relação às equações (7) e (8) foi adotado 2 e 0,5 para pwr e F respectivamente. Esses parâmetros foram obtidos por meio de testes de simulação, para verificar aquele que apresentou a melhor resposta.

Uma curva de Pareto ótimo foi proposta para uma melhor análise de custo-benefício, relacionando as perdas e custos envolvidos. Para isso, foi necessária uma alteração em (17), resultando na FO utilizada nesse trabalho que é dada pela equação (18).

$$FO = \alpha \times (F_{PI} \times P_N \times R\$/kW) + (1 - \alpha) \times F_{PC} \times C_i + (\Delta V_P + \Delta L_P) \quad (18)$$

Deve-se notar que em (18) foi adicionado um α que multiplica os componentes das perdas e um $(1 - \alpha)$ que multiplica o componente dos custos. Assim, variando o α de 0,05 a 0,95 em passos de 0,05, obtém-se uma análise das perdas por custo, pois quanto menor é α maior é a prioridade aos custos; inversamente, quando maior for α , a prioridade do algoritmo torna-se as perdas. Para o dimensionamento dos SFs nos barramentos dos sistemas utilizados neste trabalho foi utilizado $\alpha = 0,5$ para se obter um equilíbrio entre o custo e perdas. Contudo, com a variação de α é possível escolher um ponto ótimo da relação perdas vs custos que melhor enquadra-se o problema do consumidor que deseja instalar um sistema fotovoltaico em sua rede.

Para a realização de um estudo comparativo da aplicação do método proposto, também foram realizadas simulações com a rede de distribuição UFPB aplicando o MPSO com peso de inércia tradicional e com peso de inércia por decremento linear.

IV. RESULTADOS

As perdas dos alimentadores antes da inserção dos SFs eram de 111 kW, com a inserção dos módulos fotovoltaicos caindo para 14,54 kW, o que significa uma redução de 86,9% das perdas totais dos alimentadores.

Na Tabela III a alocação e dimensionamento são apresentados após a convergência ao ótimo do algoritmo. Com esses resultados pode-se observar que a potência total instalada foi de 6.160 kW, representando um custo de R\$ 38.808.000,00. A potência máxima de instalação que o algoritmo conseguiu encontrar foi de 9.480 kW (considerando uma geração fotovoltaica de 120 kW nas 79 barras), o que totaliza um custo de R\$ 59.724.000,00, portanto, a economia nesse caso foi R\$ 20.916.000,00, ou seja, uma redução de 35% do custo máximo possível.

TABELA III
ALOCAÇÃO E DIMENSIONAMENTO DOS SFs.

Potência(kW)	Barramentos
0	2;6;12;23;43;44;45;52;53;56;58;59;60;61;62;63;64;65;67 68;69;73;74;77;79
20	76;78
80	5
100	16;20;22;25
	1;3;4;7;8;9;10;11;13;14;15;17;18;19;21;24;26;27;28;29
120	30;31;32;33;34;35;36;37;38;39;40;41;42;46;47;48;49;50 51;54;57;66;70;71;72;75.

A curva de Pareto ótimo do método proposto pode ser analisada na Figura 3. Pode-se observar que para $0,05 \leq \alpha \leq 0,15$ não há variação nos valores de perdas. Isso ocorre porque o algoritmo "interpreta" que não se deve alocar sistema fotovoltaico para esses α , porque qualquer potência alocada causará um FO maior do que sem SFs. Quando $\alpha \geq 0,2$ a instalação dos SFs já influencia as perdas do sistema; porém, ao priorizar o ($\alpha \rightarrow 1$), os custos de instalação são aumentados, uma vez que será necessário instalar mais módulos fotovoltaicos para garantir menor perda do sistema.

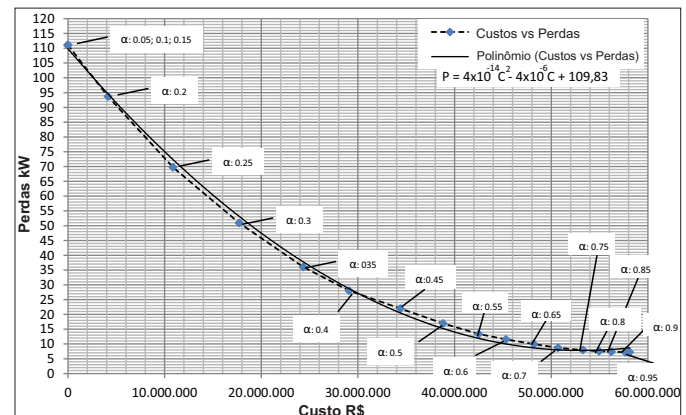


Fig. 3. Pareto ótimo Perdas vs Custos R\$.

Através da Figura 3 o analista pode optar por priorizar as perdas ou custos de instalação selecionando o α desejado. Também é possível observar que à medida que α aumenta as variações das perdas são menores, levando à conclusão de que o sistema possui uma certa "saturação", ou seja, independente

do investimento feito na alocação dos SFs a redução de perdas tornam-se cada vez menos significativas.

Por meio dos valores obtidos na Figura 3 com a variação de α , foi possível caracterizar e encontrar uma equação que representa a curva que intercepta os pontos (mostrada na legenda da figura). Através desta equação pode-se calcular as perdas do sistema P de acordo com o investimento realizado C .

A. Análise Comparativa do MPSO-MD, MPSO Tradicional e MPSO com Decremento Linear

Na análise comparativa dos métodos utilizou-se a pior partícula do enxame (F_{worse}), pois o algoritmo depende desta para avaliar o critério de parada, como pode ser observado em (10). A Figura 4 mostra o comportamento de F_{worse} ao longo das iterações, aplicando os métodos do MPSO-MD, MPSO tradicional e MPSO com decremento linear, para $\alpha = 0,5$. É possível observar que o método que apresenta o menor número de iterações é o MPSO tradicional, convergindo em 10 iterações, o MPSO-MD e MPSO por decremento linear respectivamente, convergem em 19 e 134 iterações. Contudo, o uso do MPSO-MD possibilitou encontrar uma função objetivo menor, FO = R\$ 281.475,3723, enquanto o MPSO com decremento linear e MPSO tradicional apresentou, respectivamente, FO = R\$ 286.165,3861 e FO = R\$ 284.111.0443. Observa-se que a utilização do MPSO-MD proporcionou uma maior exploração do espaço de busca, encontrando uma melhor solução.

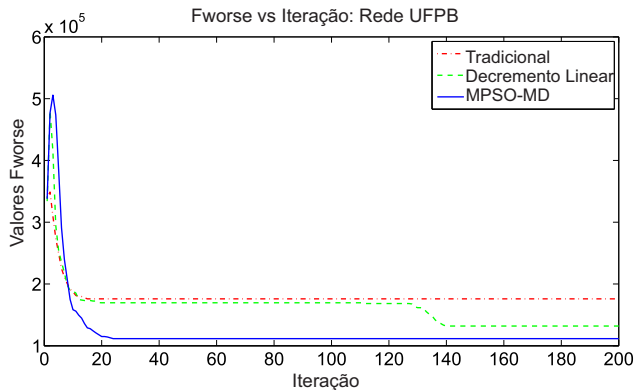


Fig. 4. Evolução da FO para $\alpha = 0,5$.

Da mesma maneira, é proposta uma análise gráfica do comportamento de F_{worse} para $\alpha = 0,1$ e $0,9$. Os gráficos estão ilustrados na Figura 5. De modo análogo a Figura 4, observa-se que o MPSO-MD não se apresenta como a técnica mais rápida em convergência entre as comparadas, contudo, é a que apresenta melhor ponto ótimo em relação aos demais métodos.

A Tabela IV mostra os resultados obtidos a partir dos métodos empregados, com a melhor (F_{best}) e a pior (F_{worse}) funções objetivos, de um total de 20 repetições de simulação.

Uma análise importante a ser feita é sobre o comportamento do MPSO-MD à variação de α . Quando $\alpha \rightarrow 0$ a prioridade em FO são os custos, que estão diretamente relacionados à potência nominal dos SFs, dada por valores inteiros. Nesta

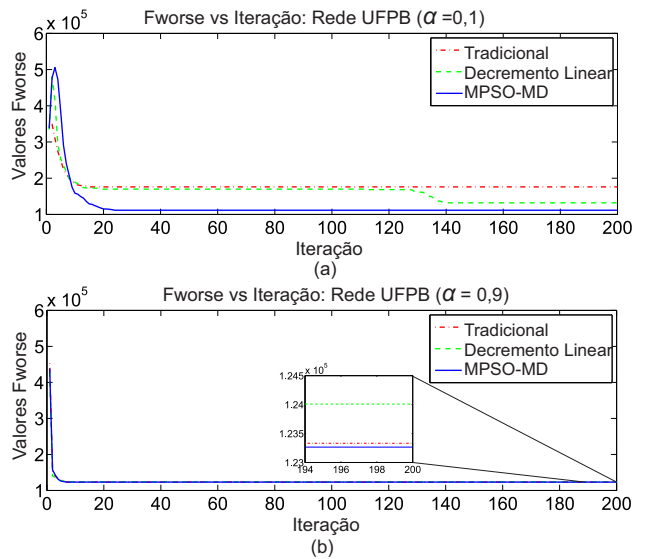


Fig. 5. Evolução da FO para (a) $\alpha = 0,1$ e (b) $\alpha = 0,9$.

TABELA IV
COMPARAÇÃO DOS MÉTODOS EMPREGADOS EM FUNÇÃO DO PESO DE INÉRCIA.

α	Método MPSO	F_{worse}	F_{best}	Iteração
0.1	Tradicional	175 965.0413	174 205.3909	15
	Decremento Linear	131 992.8568	131 068.9068	140
	MPSO-MD	111 597.9823	110 694.0386	24
0.3	Tradicional	278 422.4001	276 863.2347	9
	Decremento Linear	275 572.0922	272 981.7145	133
	MPSO-MD	274 943.9944	272 881.9140	21
0.5	Tradicional	286 165.3861	283 933.2961	9
	Decremento Linear	284 111.0443	282 264.3225	134
	MPSO-MD	281 475.3723	279 814.6676	19
0.7	Tradicional	218 014.5421	216 532.0432	7
	Decremento Linear	218 994.4862	217 965.2121	7
	MPSO-MD	216 577.1137	214 454.6580	16
0.9	Tradicional	123 331.6507	122 369.6638	7
	Decremento Linear	124 008.5268	123 202.4714	9
	MPSO-MD	123 265.4351	122 156.0462	8

ocasião, o método desenvolvido é muito mais eficiente na exploração do espaço de busca, obtendo valores de FO menores, quando comparado ao MPSO tradicional e por decremento linear. Quando $\alpha \rightarrow 1$ a prioridade da FO passa a ser as perdas, que tem a característica de ser uma quantidade não inteira (valores reais). Neste caso o comportamento do MPSO-MD passa a se aproximar dos demais métodos. Este fato pode ser claramente observado através da Figura 5, demonstrando que o MPSO-MD apresenta melhor desempenho quando a FO é fortemente influenciada por variáveis com valores inteiros.

Através da análise dos resultados obtidos com o uso do MPSO-MD em sistemas de grande dimensão, em geral, percebe-se o aprimoramento do algoritmo na exploração do espaço de busca na procura do ótimo global. Isso porque o método não atualiza as dimensões das partículas individualmente, a atualização das dimensões é feita levando em consideração as variações de velocidade de todas as partículas e de todas as dimensões, o que acaba contribuindo para a melhoria no desempenho do algoritmo.

V. CONCLUSÕES

Neste artigo é proposto o método MPSO-MD para alocação e dimensionamento ótimo de SFs em sistemas de distribuição, visando à redução de perdas, diminuindo os custos envolvidos na instalação dos sistemas fotovoltaicos e consequentemente a melhoria do perfil de tensão na rede.

Devido à dificuldade apresentada pelo algoritmo MPSO tradicional em problemas de grandes dimensões, o MPSO-MD foi utilizado como alternativa. Desta forma foi possível explorar melhor o espaço de busca, obtendo valores menores de FO, principalmente quando $\alpha \rightarrow 0$. Portanto, pode-se concluir que o MPSO-MD funciona melhor quando se trabalha com variáveis inteiras. Utilizando o método proposto, com $\alpha = 0,5$, o dimensionamento dos SFs proporcionou uma redução nas perdas totais em aproximadamente 86,9%. Como consequência da redução de perdas as redes tendem a se beneficiarem com o aumento dos níveis de tensão nos seus barramentos. O custo otimizado do investimento também pôde ser reduzido em 35%, evitando custos desnecessários para quem deseja instalar sistemas fotovoltaicos em suas redes.

Com base nos resultados obtidos, pode-se concluir que o método proposto, apesar de não ser o mais rápido em convergência, apresenta-se como uma ferramenta competitiva no que se refere ao dimensionamento de SFs em sistemas de distribuição, especialmente em problemas de grandes dimensões, explorando plenamente o espaço de busca e encontrando melhores soluções quando comparadas ao MPSO tradicional e ao método do decremento linear.


AGRADECIMENTOS

Os autores agradecem a Universidade Federal de Pernambuco e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

REFERÊNCIAS

- [1] I. E. Agency, *World Energy Outlook 2017*, vol. 4 of 10. 3 ed., 7 2017.
- [2] F. A. C. M. dos Santos and F. M. S. M. dos Santos, "Geração distribuída versus centralizada," *Millenium-Journal of Education, Technologies, and Health*, vol. 35, no. 13, 2016.
- [3] L. d. M. Guedes, *Alocação de unidades de geração distribuída considerando perdas e aspectos econômicos*. PhD thesis, Universidade de Brasília, Distrito Federal, 2013.
- [4] M. Albadi, H. Soliman, M. A. Thani, A. Al-Alawi, S. Al-Ismaili, A. Al-Nabhani, and H. Baalawi, "Optimal allocation of pv systems to minimize losses in distribution networks using ga and pso: Masirah island case study.," *Journal of Electrical Systems*, vol. 13, no. 4, 2017.
- [5] A. Khare and S. Rangnekar, "A review of particle swarm optimization and its applications in solar photovoltaic system," *Applied Soft Computing*, vol. 13, no. 5, pp. 2997–3006, 2013.
- [6] M. Pesaran H.A., P. D. Huy, and V. K. Ramachandaramurthy, "A review of the optimal allocation of distributed generation: Objectives, constraints, methods, and algorithms," *Renewable and Sustainable Energy Reviews*, vol. 75, pp. 293–312, 2017.
- [7] A. A. Hassan, F. H. Fahmy, A. E.-S. A. Nafeh, and M. A. Abu-elmagd, "Genetic single objective optimisation for sizing and allocation of renewable dg systems," *International Journal of Sustainable Energy*, vol. 36, no. 6, pp. 545–562, 2017.
- [8] S. Dahal and H. Salehfar, "Optimal location and sizing of distributed generators in distribution networks," in *2013 North American Power Symposium (NAPS)*, pp. 1–6, 2013.
- [9] P. Prakash and D. K. Khatod, "Optimal sizing and siting techniques for distributed generation in distribution systems: A review," *Renewable and Sustainable Energy Reviews*, vol. 57, pp. 111 – 130, 2016.

- [10] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 4, pp. 1942–1948 vol.4, 1995.
- [11] M. H. Albadi, H. M. Soliman, E. F. El-Saadany, M. A. Thani, A. Al-Alawi, S. Al-Ismaili, A. Al-Nabhani, and H. Baalawi, "Optimal allocation of pv systems in distribution networks using pso," in *2017 7th International Conference on Modeling, Simulation, and Applied Optimization (ICMSAO)*, pp. 1–5, 2017.
- [12] S. M. Arif, A. Hussain, and D. R. Shin, "A survey on particle swarm optimization for use in distributed generation placement and sizing," in *MATEC Web of Conferences*, vol. 70, p. 10013, 2016.
- [13] A. Jayavarma and T. Joseph, "Optimal placement of solar pv in distribution system using particle swarm optimization," *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 2, pp. 329–337, 2013.
- [14] J. S. de Souza, Y. P. Molina, C. S. de Araujo, W. P. de Farias, and I. S. de Araujo, "Modified particle swarm optimization algorithm for sizing photovoltaic system," *IEEE Latin America Transactions*, vol. 15, no. 2, pp. 283–289, 2017.
- [15] K. Bhumkittipich and W. Phuangpornpitak, "Optimal placement and sizing of distributed generation for power loss reduction using particle swarm optimization," *Energy Procedia*, vol. 34, pp. 307 – 317, 2013. 10th Eco-Energy and Materials Science and Engineering Symposium.
- [16] M. Mohammadi and M. A. Nasab, "Pso based multiobjective approach for optimal sizing and placement of distributed generation," *Research Journal of Applied Sciences, Engineering and Technology*, vol. 2, no. 8, pp. 832–837, 2011.
- [17] Y. A. Beromi, M. Sedighzadeh, and M. Sadighi, "A particle swarm optimization for siting and sizing of distributed generation in distribution network to improve voltage profile and reduce thd and losses," in *2008 43rd International Universities Power Engineering Conference*, pp. 1–5, Sep. 2008.
- [18] E. T. Oldewage *et al.*, *The perils of particle swarm optimization in high dimensional problem spaces*. PhD thesis, University of Pretoria, 2017.
- [19] T. Hendtlass, "Particle swarm optimisation and high dimensional problem spaces," in *2009 IEEE Congress on Evolutionary Computation*, pp. 1988–1994, May 2009.
- [20] J. Xin, G. Chen, and Y. Hai, "A particle swarm optimizer with multi-stage linearly-decreasing inertia weight," in *2009 International Joint Conference on Computational Sciences and Optimization*, vol. 1, pp. 505–508, April 2009.
- [21] Y. Shi and R. Eberhart, "A modified particle swarm optimizer," in *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, pp. 69–73, May 1998.
- [22] R. C. Eberhart and Y. Shi, "Tracking and optimizing dynamic systems with particle swarms," in *Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)*, vol. 1, pp. 94–100 vol. 1, May 2001.
- [23] G. Chen, X. Huang, J. Jia, and Z. Min, "Natural exponential inertia weight strategy in particle swarm optimization," in *2006 6th World Congress on Intelligent Control and Automation*, vol. 1, pp. 3672–3675, June 2006.
- [24] A. F. Moreira, "Alocação e dimensionamento de painéis fotovoltaicos utilizando otimização por enxame de partículas para reduzir as perdas visando os aspectos econômicos," Master's thesis, Universidade Federal da Paraíba, João Pessoa, 2018.
- [25] I. PVPS *et al.*, "Trends in photovoltaic applications," *Survey report of selected IEA countries between 1992 and 2015*, 2016.




Alex F. Moreira Possui o título de engenheiro elétrico (2016) pelo Instituto Federal da Paraíba, João Pessoa, Brasil e mestrado em 2018 pela Universidade Federal da Paraíba, João Pessoa, Brasil. Atualmente é estudante de doutorado do programa de pós graduação da Universidade Federal de Pernambuco. Seus interesses estão na operação de sistemas elétricos com inserção de fontes renováveis de energia não convencionais.



Yuri P. M. Rodriguez Possui graduação em engenharia elétrica pela Universidade Nacional de Engenharia, Lima, Peru e Doutorado em engenharia elétrica (2009) pela Universidade Católica do Rio de Janeiro, Brasil. Atualmente é professor adjunto do departamento de engenharia elétrica da Universidade Federal da Paraíba. Seus interesses incluem operação de sistemas elétricos em ambientes competitivos.



Zocimo Ñaupari Possui graduação em engenharia elétrica em 1998 pela Universidade Nacional de Engenharia, Lima, Peru e mestrado em 2006 pela Universidade Federal do Maranhão, São Luiz, Brasil. Atualmente trabalha como professor da Universidade Federal de Engenharia, Lima, Peru. Seus interesses de pesquisa incluem a otimização de sistemas elétricos de potência, com ênfase em métodos heurísticos, bem como o desenvolvimento de novos mercados de energia.



Ronaldo R. B. de Aquino Possui graduação em engenharia elétrica pela Universidade Federal de Pernambuco (1983), Recife, Brasil e doutorado em engenharia elétrica pela Universidade Federal da Paraíba, Campina Grande, Brasil (2001). Atualmente é professor titular do departamento de engenharia elétrica da UFPE. Seus interesses de pesquisa incluem a aplicação de inteligência artificial em problemas de geração, transmissão e distribuição de energia elétrica.