



## CAPÍTULO 7

# Reconfiguração otimizada de redes de distribuição levando-se em conta a geração fotovoltaica e os armazenadores de energia

### 7.1 INTRODUÇÃO

A conexão de GD fotovoltaicos (PV) a sistemas de energia não responde às variações elétricas do sistema da mesma forma que um gerador síncrono convencional. A fonte solar possui características únicas, como resposta de alta velocidade (baixa inércia) e alta taxa de variação para rampas de potência. Vários estudos, como os de Degefa *et al.* (2015), Golmohamadi e Keypour (2017) e Ismail (2016), tratam das preocupações associadas à alta penetração da geração distribuída nos sistemas de distribuição, tendo como consequências variações de tensão, variações de frequência e redução de perdas técnicas.

No que diz respeito à minimização de perdas técnicas de potência, uma solução base *particle swarm optimization* (PSO) é apresentada neste capítulo, mostrando eficiência e simplicidade na sua implementação (Soares *et al.*, 2015).

A minimização de perdas técnicas por meio da reconfiguração da rede de distribuição vem apresentando resultados promissores. Por exemplo, em Su, Chang e Chiou (2005), os autores introduziram um algoritmo de busca de colônias de formigas para resolver o problema de reconfiguração de rede otimizada para redução

de perdas técnicas. Esse algoritmo de colônia de formigas foi comparado a outros dois métodos: um algoritmo de otimização genética e um algoritmo de recozimento simulado. A comparação mostrou que a solução de colônia de formigas apresentou melhores resultados. Para mitigar distúrbios na qualidade de energia, Jazebi e Vahidi (2012) apresentaram uma solução para lidar com harmônicos, afundamentos de tensão e minimização de perdas de energia por reconfiguração da rede baseada em algoritmo de evolução diferencial. A rede reconfigurada demonstrou a eficácia da solução proposta, permitindo a melhoria dos indicadores de qualidade de energia e diminuição das perdas.

Em Pfitscher *et al.* (2013), um sistema inteligente de reconfiguração automática de uma rede de distribuição baseado na adaptação da central de ramais é utilizado para resolver problemas em tempo real, como redução de perdas, equilíbrio de carga e melhoria de indicadores de qualidade. Os autores testaram a metodologia proposta em uma grade real e os resultados mostraram melhora nos indicadores de desempenho da rede. Em Teimourzadeh e Zare (2014), os autores apresentam uma estratégia de reconfiguração de rede por meio do uso do algoritmo de busca de grupo binário. O objetivo de otimização foi a redução das perdas na rede. Segundo os autores, a simulação de diferentes casos de teste validou a solução proposta. A reconfiguração otimizada da rede de distribuição com algoritmos genéticos foi apresentada em Gupta, Swarnkar e Niazi (2014) para melhoria da qualidade e confiabilidade da energia. Henrique *et al.* (2013) propuseram um algoritmo evolutivo baseado em NSGA-II para resolver um problema multiobjetivo em uma reconfiguração de rede distribuída. As conclusões mostraram que o método proposto é capaz de lidar com as incertezas encontradas na análise.

Em Than e Viet (2014), uma reconfiguração otimizada da rede de distribuição para minimização de perdas técnicas e melhoria do perfil de tensão é obtida por meio do algoritmo de busca cuco. A simplicidade do algoritmo mostrou que ele pode ser um método eficiente para problemas de reconfiguração de redes de distribuição. Uma reconfiguração robusta para minimização de perdas ativas utilizando a técnica do cenário mais provável (MPS) é apresentada em Chittur, Tant e Radhakrishna (2015). Os autores utilizam o conceito de controle de horizonte recuado, concluindo que ambas as técnicas são adequadas para lidar com o problema de minimização apresentado. Em Fathabadi (2016), o problema de reconfiguração para minimização de perdas de potência é resolvido usando uma nova rede neural artificial (RNA) baseada em agrupamento dinâmico *fuzzy c-means*. Um tempo de processamento muito curto, estrutura simples e alta precisão são considerados os benefícios do método proposto. O poder da otimização por enxame de partículas binárias (BPSO) pode ser visto em Pegado *et al.* (2019). Os autores mostraram que esse algoritmo é uma ferramenta

poderosa para redução de perdas, realizando a reconfiguração da rede de distribuição, ao mesmo tempo que pode alcançar a otimização global.

Diferentemente dos trabalhos anteriores, nesse estudo foram utilizados sistemas de armazenamento de energia (EES) e inteligência artificial (IA) para reconfiguração otimizada de redes de distribuição de energia elétrica com penetração fotovoltaica. Para tanto, um alimentador de teste de modelo IEEE de 37 barramentos modificado é utilizado como cenário de aplicação. Tais modificações foram novos caminhos introduzidos no alimentador de teste original para que se possa ter rotas alternativas para o fluxo de potência.

As principais contribuições do presente estudo são:

- O desenvolvimento de um BPSO para a topologia otimizada de uma rede de distribuição, no que diz respeito à minimização das perdas técnicas de potência.
- A utilização de uma RNA para estimar a geração fotovoltaica e desempenho do ESS, para melhoria de desempenho da rede reconfigurada.
- A solução apresentada contribui para a redução de perdas técnicas por meio da reconfiguração otimizada de uma rede de distribuição, o que não era feito anteriormente, como o atual estado da arte e da literatura.

## 7.2 MATERIAIS E MÉTODOS

Esta seção traz as ferramentas e a metodologia utilizadas para alcançar os resultados apresentados neste trabalho.

### 7.2.1 PSO binário (BPSO)

O clássico *particle swarm optimization* (PSO) foi desenvolvido para funções de otimização contínuas, e não para funções de otimização discretas. Portanto, Eberhart e Shi (2004); Wu, Tsai e Hsu (2007); Pampara, Frankem e Engelbrecht (2005) e Baioletti, Milani e Santucci (2017) propuseram uma versão binária para o PSO denominada *binary particle swarm optimization*.

Nos sistemas de distribuição de energia elétrica, a reconfiguração dos alimentadores é realizada por meio da abertura e fechamento de dispositivos de manobra. A mudança na posição dessas chaves pode reduzir as perdas nas linhas ou operar o sistema com maior segurança, como pela utilização de métodos de contingência. A estrutura resultante dessa comutação deve obedecer automaticamente à estrutura radial de um sistema de distribuição. Para tal configuração, o PSO pode ser utilizado para que sejam encontradas topologias ótimas para os sistemas em estudo.

O objetivo principal da reconfiguração do sistema de distribuição é minimizar as perdas técnicas totais nas linhas durante a sua operação normal. Esse problema pode ser formulado por (7.1):


$$L_{losses} = \sum_{i=1}^n I_i^2 \cdot R_i \quad (7.1)$$

onde  $L_{losses}$  são as perdas técnicas totais do sistema de distribuição,  $n$  é o número total de trechos de linha do sistema,  $I_i$  é o valor da corrente elétrica da  $i$ -ésima zona e  $R_i$  é a resistência do  $i$ -ésimo trecho de linha.

Para resolver esse problema, Wu, Tsai e Hsu (2007) propõem um BPSO modificado, que é o método utilizado neste estudo. Esse método define o operador de deslocamento (SO, do inglês *shift operator*) e o conjunto de operadores de deslocamento (SOS, do inglês *shift operator set*). O problema de reconfiguração de um sistema de distribuição pode ser tratado como uma otimização de permutação combinatória de '1' e '0', onde uma chave normalmente fechada (NC) corresponde a '1' e uma normalmente aberta (NO) a '0'.

#### 7.2.1.1 Shift operator (SO)

Suponhamos que um sistema de distribuição possua uma determinada quantidade de chaves NF e NA. O status da combinação de chaves NC + NO é  $[S_1, S_2, \dots, S_n]$  e será chamado de *sequence switch states* (SSS). Por exemplo, uma partícula ou indivíduo pode ser representado por uma sequência de zeros e uns. Nesse exemplo, uma partícula é um vetor binário com um conjunto de trechos de linha NC + NO. Para um sistema que contém em sua configuração 9 chaves, conforme mostrado na Figura 7.1, o SSS passa então a ser:



**Figura 7.1** Configuração inicial do sistema utilizado como exemplo (fd – feeder).

Fonte: elaborada pelo autor.


$$SSS = x_i^k = \begin{matrix} [S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9] \\ [110111011] \end{matrix} \quad (7.2)$$

O SO é definido como um vetor de três dimensões, que armazena as seguintes informações:

- Qual bit de solução será deslocado.
- Em qual direção esse bit será deslocado (direita (R) ou esquerda (L)).
- Quantas posições o bit será deslocado de acordo com a direção atribuída.

A nova permutação SSS é definida por  $SSS' = SSS <+> SO$ . O símbolo  $<+>$  indica que o operador shift foi aplicado ao vetor SSS.

Por exemplo, a Figura 7.2 ilustra a aplicação do SO no SSS, resultando no SSS', ou seja, o novo conjunto de zeros e uns para uma determinada partícula ou indivíduo após a aplicação do operador de deslocamento. Como se pode ver, o operador shift moveu o terceiro bit (0), uma posição para a direção direita (3, R, 1).



**Figura 7.2** Aplicação do operador de turno SO.

Fonte: elaborada pelo autor.

### 7.2.1.2 Shift operator set (SOS)

O operador de deslocamento (SO) pode conter mais de uma operação, ou seja, um conjunto de operações pode ser realizado na mesma etapa. Um exemplo seria imaginar dois operadores  $SO_1$  e  $SO_2$ . Por meio da fusão entre os dois operadores, obtém-se o operador de deslocamento SOS resultante, tal que  $SOS = \{SO_1, SO_2\} = SSS_1 \ominus SSS_2$ , sendo  $SSS_1$  e  $SSS_2$  as duas partículas ou soluções (diferentes sequências de comutação NO e NC). O SOS é, de fato, encontrado comparando as posições dos interruptores, uma por uma. O operador  $\ominus$  é utilizado para indicar a geração dos operadores de turno  $SSS_1$  e  $SSS_2$ .

### 7.2.1.3 BPSO modificado

Com a definição dos operadores necessários dados pelo algoritmo modificado, o BPSO pode ser definido para resolver problemas de reconfiguração de topologias de sistemas de distribuição de energia elétrica aplicando (7.3) em (7.4).

$$x_i^{k+1} = x_i^k + V_i^{k+1} \quad (7.3)$$

onde

- $x_i^{k+1}$  é a posição de uma partícula no instante  $k+1$ .
- $x_i^k$  é a posição no instante  $k$ .
- $V_i^{k+1}$  é a velocidade nova e ajustada que será aplicada à partícula.

$$V_i^{k+1} = (w \otimes V_i) \oplus (rand() \times (pbest \ominus x_i)) \oplus (rand() \times (gbest \ominus x_i)) \quad (7.4)$$


onde

- $w$  é o operador de inércia.
- $V_i$  é a velocidade no tempo  $k$ .
- $pbest$  é a melhor posição pessoal da partícula.
- $gbest$  é a melhor posição global entre todas as partículas.
- $x_i$  é a posição real da partícula  $i$ .

A função do operador  $w$  é mantida nesse processo para ajustes nas áreas de busca. A abordagem do modelo BPSO adotada consiste em aumentar ou diminuir o passo a ser dado pelo operador de deslocamento a cada iteração. Assim,  $\otimes$  aplica o valor de  $w$  calculado ao tamanho do operador que consiste no passo de deslocamento.

A composição do coeficiente  $rand()$  com o símbolo  $\times$  executa uma operação, para a qual a ação é escolher aleatoriamente um operador de deslocamento dentre os operadores agrupados em  $(pbest \ominus x_{id})$  e  $(gbest \ominus x_{id})$ .

No exemplo anterior (Figura 7.2), conforme o SO resultante, o bit 3 foi deslocado para a direita, representado pela letra R, posição 1. Nessa operação, para que a radialidade do sistema fosse mantida, apenas 2 chaves poderiam permanecer abertas. Assim, a chave que corresponde a 3 ( $S_3$ ) passou do estado NO (0) para o estado NC (1). Portanto, a nova configuração do sistema é apresentada na Figura 7.3.



**Figura 7.3** Configuração final do sistema após o SO aplicado.

Fonte: elaborada pelo autor.

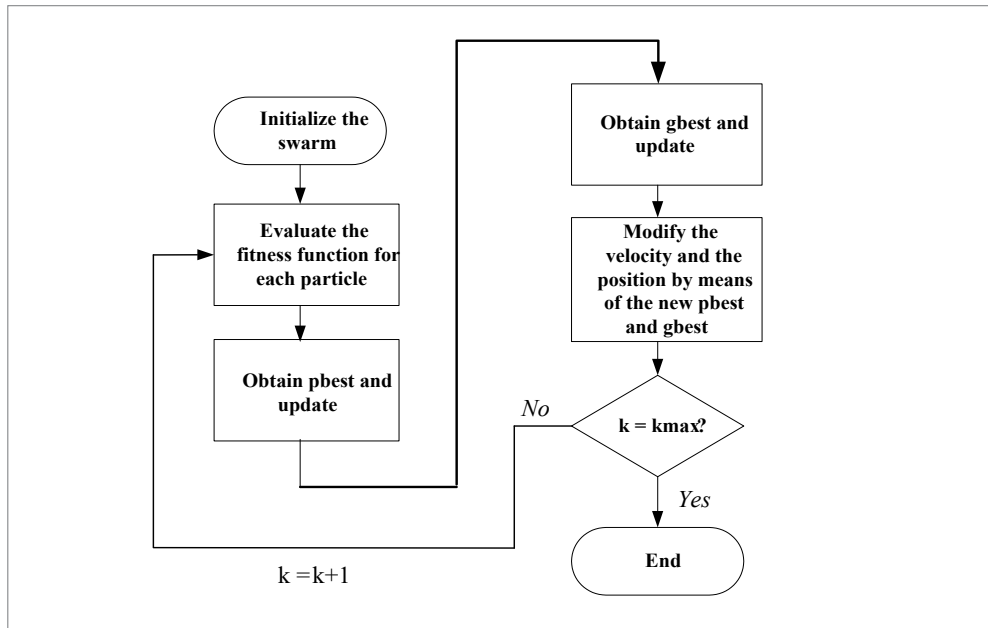
O procedimento para implementação do algoritmo PSO segue os passos descritos em Wu, Tsai e Hsu (2007):

1. Escolha o tamanho da população (diferentes vetores binários que contêm combinações de chaves NO e NC), bem como o número máximo de iterações desejadas.
2. Inicie o SSS e os operadores de deslocamento SO aleatoriamente para aplicação às partículas.
3. Para cada partícula, avalie a função de aptidão de otimização desejada.
4. Compare a avaliação da etapa 2 com a  $pbest$  de cada partícula. Se o valor atual for melhor que o valor anterior, atualize o atual  $pbest$  como o novo  $pbest$ , incluindo o SSS e o valor da aptidão para  $pbest$ .
5. Compare a avaliação de cada um  $pbest$  com o melhor valor de avaliação anterior da população. Se o valor real for melhor que o anterior  $gbest$ , atualize o valor de  $gbest$ , incluindo o SSS e o valor da  $gbest$  aptidão.
6. Atualize o operador de turno SO e gere um novo estado de operação para os switches (SSS) e o valor de fitness para o  $gbest$ .



7. Repita o passo 3 até que um critério de parada seja satisfeito; isso geralmente significa um número máximo de iterações, de forma que esse número seja adequado para garantir uma função de aptidão de boa qualidade.

A Figura 7.4 apresenta o fluxograma do algoritmo utilizado.



**Figura 7.4** Fluxograma do BPSO.

Fonte: elaborada pelo autor.


## 7.2.2 Técnica para a verificação de barras isoladas no sistema de distribuição (SD)

Diversas topologias de sistema diferentes podem ser representadas por meio de diagramas compostos por um conjunto de pontos e linhas que se interligam. Por exemplo, os pontos podem ser os cantos de uma cidade e as linhas as ruas; também os pontos podem ser cidades e as linhas, rotas de voo percorridas pelos aviões; ou ainda, os pontos podem ser barramentos de um sistema elétrico e as linhas, suas linhas de transmissão ou distribuição. A abstração matemática de situações desse tipo dá origem ao conceito de gráfico.

O meio mais prático de representar a conectividade entre barramentos no SD é utilizar grafos em cadeia. Um sistema de distribuição de energia, dada a sua radialidade, pode ser representado por uma floresta de grafos. Nesta seção, é apresentada

uma introdução à teoria dos grafos, juntamente com um método simples para representar um sistema radial.

Tomando como exemplo o gráfico da Figura 7.5 e considerando cada vértice como uma barra e cada aresta como uma linha de um sistema de distribuição, o primeiro passo é obter o mapeamento das linhas relacionando seus terminais de barramento e suas origens. Para concluir, os números substituíram a nomenclatura dos vértices e arestas para facilitar a compreensão do método utilizado, o que resultou na Figura 7.5.



**Figura 7.5** Representação de um sistema de matriz elétrica.  
Fonte: elaborada pelo autor.

A Tabela 7.1 é usada para determinar a conectividade de cada barramento.

**Tabela 7.1** Conectividade dos barramentos do sistema representado na Figura 7.5

Linha	Barra inicial	Barra final
1	1	2
2	2	3
3	2	4
4	4	5
5	5	6
6	6	7
7	3	7
8	2	6
9	5	10
10	6	9
11	7	8
12	10	9
13	9	8

Fonte: elaborada pelo autor.

A partir desse ponto, utiliza-se o conceito de matriz de adjacência e matriz laplaciana (Brooks; Barooah, 2016), e chamaremos o gráfico representado na Figura 7.5 de  $G$ .

Dado o gráfico  $G = (V, E)$  com  $n$  vértices, a matriz de adjacência da matriz  $G$  é a matriz de ordem  $n$  dada por  $A(G) = [a_{ij}]$ , aqui  $a_{ij} = 1$  se  $v_i v_j \in E$ , sendo  $E$  a energia do gráfico, e  $a_{ij} = 0$  nas demais entradas.

A matriz laplaciana de  $G$  é a matriz de ordem  $n$  dada por  $L(G) = [l_{ij}]$ , onde  $l_{ij} = -1$  se  $v_i v_j \in E$ ,  $l_{ij} = d(v_i)$  e  $l_{ij} = 0$  nas entradas restantes. A matriz laplaciana e a matriz de adjacência estão relacionadas da seguinte maneira (7.5):

$$L = D - A \quad (7.5)$$

onde  $D$  é a matriz diagonal com os graus dos vértices. Para ilustrar essa teoria, é dado o seguinte exemplo.

A matriz  $a$  é formada de modo que suas linhas e colunas correspondam ao número de barras do sistema, obtendo-se assim uma matriz quadrada. Nesse caso específico, tem-se uma matriz de  $10 \times 10$ . O valor -1 é atribuído para indicar a conectividade entre os barramentos. As barras que não possuem conectividade entre si recebem o valor 0. Por exemplo, ao elemento  $a_{2,3}$  da matriz  $a$  é atribuído o valor -1, indicando a conectividade entre as barras 2 e 3. Porém, em  $a_{2,10}$ , o valor 0 é atribuído, pois a barra 2 não possui conectividade com a barra 10. Este processo é realizado em todas as barras e, por fim, os valores atribuídos a cada coluna da matriz  $a$  são somados e armazenados na diagonal principal que corresponde a cada barra. Para melhor compreensão desse conceito, outro exemplo é dado.

Se considerarmos que nenhuma reta está aberta, a matriz  $a$  teria a composição mostrada na Figura 7.6.

$$\begin{array}{r}
 \begin{array}{cccccccccc}
 -1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 -1 & -4 & -1 & -1 & 0 & -1 & 0 & 0 & 0 & 0 \\
 0 & -1 & -2 & 0 & 0 & 0 & -1 & 0 & 0 & 0 \\
 0 & -1 & 0 & -2 & -1 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 & 0 & -1 \\
 a = & 0 & -1 & -1 & 0 & -1 & -4 & -1 & 0 & -1 & 0 \\
 0 & 0 & 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & -1 & -2 & -1 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & -1 & 0 & -1 & -3 & -1 & 0 \\
 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & -1 & -2 & 0
 \end{array}
 \end{array}$$

**Figura 7.6** Matriz  $a$  para o caso em que todas as linhas estão ativas.

Fonte: elaborada pelo autor.

Verifica-se que as somas dos valores armazenados nas colunas correspondentes a cada barra foram somadas e atribuídas à linha diagonal principal da matriz. Agora, considere que a linha 2 e a linha 6 do sistema representado na Figura 7.6 foram removidas da configuração. A matriz  $a$  mudará sua composição, conforme mostrado na Figura 7.7.

$$a = \begin{bmatrix} -1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & -3 & 0 & -1 & 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & -1 & 0 & -2 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & -3 & -1 & 0 & 0 & 0 & -1 \\ 0 & -1 & -1 & 0 & -1 & -3 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -2 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 & 0 & -1 & -3 & -1 \\ 0 & 0 & 0 & 0 & -1 & 0 & 0 & 0 & -1 & -2 \end{bmatrix}$$

**Figura 7.7** Matriz  $a$  para o caso das linhas 2 e 6 como inativas ou abertas.

Fonte: elaborada pelo autor.

Utilizando a Figura 7.7, pode-se observar, nos elementos destacados, que os valores atribuídos às diagonais principais, que correspondem aos barramentos aos quais as linhas retiradas estavam conectadas, de fato, tiveram uma redução em seus valores. Dessa forma, o resultado do somatório nas diagonais correspondentes às barras 2, 3, 6 e 7 (Figura 7.5) é inferior ao da Figura 7.6.

A viabilidade consiste, portanto, em detectar quais configurações da matriz  $a$  são permitidas e quais não são, para que o sistema seja solucionável ou viável. Portanto, pode ser verificado pelos elementos da diagonal principal que apresentam o valor 0. Isso significaria que o barramento que corresponde àquela coluna está isolado. Assim, o sistema isolaria um barramento e, como tal, uma solução com este tipo de configuração não seria viável. Quanto maior a complexidade do sistema, maior será o número de análises e casos para observação, chegando, assim, à possibilidade de métodos iterativos.

### 7.2.3 Metodologia

Para validar o desempenho do algoritmo de otimização BPSO, foram realizados três estudos de caso e foi considerado o alimentador de teste da barra IEEE 37 modificado, conforme mostrado na Figura 7.8. A modificação é a adição de geradores distribuídos nas barras 710, 711 e 741. Os geradores distribuídos foram colocados nesses locais por estarem mais afastados da fonte principal (barra 799), o que lhes permite ter maior atuação em todo o sistema. Ressalta-se que as perdas do sistema sem a mudança de topologia e adição de sistema de armazenamento de energia foram de 0,03921 pu.

Para esse estudo, foi feita análise estática, ou seja, não foi considerada a demanda variável. Portanto, o fluxo de potência das cargas e as injeções de potência estão relacionados ao período em que ocorre a geração fotovoltaica máxima. Uma RNA estima a geração fotovoltaica e seus dados foram utilizados nos casos 2 e 3. Essas informações podem ser encontradas na próxima seção (7.2.3.1). Além disso, o fluxo de potência, o BPSO e os algoritmos de teste de viabilidade foram desenvolvidos em script MatLab.

Como o sistema é puramente radial e sem recursos distribuídos (geradores distribuídos), torna-se necessária a adição de rotas alternativas, criando assim um sistema com recurso. Além disso, o custo adicional resultante da adição de novas seções não deve ser tomado em consideração. Portanto, deve-se tratar o sistema como se já existisse da forma proposta e ilustrada na Figura 7.8.



Todas as seções adicionadas foram atribuídas com os mesmos parâmetros de linha das seções 701-702, pois a maior parte do fluxo de potência é originalmente encontrada nesta seção. Porém, a condição que não é suficiente para que uma topologia seja radial é encontrada em (7.6) (Civanlar *et al.*, 1988):

$$\text{Linhas} = \text{barras} - 1 \quad (7.6)$$

com

- Linhas – o número de linhas do sistema.
- Trechos – o número de trechos do sistema.

O número de chaves que podem ser abertas para a reconfiguração pode ser determinado por (7.7):

$$\text{Interruptores} = \text{Lines}_m - \text{Lines}_r \quad (7.7)$$

onde

- $\text{Lines}_m$  é o número de linhas do sistema em *loop*.
- $\text{Lines}_r$  é o número de linhas do sistema radial.

Portanto, para o caso em análise, um total de 5 chaves deverão estar abertas para reconfiguração, já que o sistema possui 42 trechos após as modificações.

O espaço de busca para o problema pode ser obtido pela análise combinatória, em que o número de combinações de elementos NB tomados de N a N é definido como (7.8) (Ubirajara; Nunes; Nunes, 2017):

$$C_{NB}^N = \frac{NB!}{N!(NB-N)!} \quad (7.8)$$

Conforme (7.8), o espaço de busca resulta em 850.668 possibilidades, justificando assim a utilização de um algoritmo de otimização para resolução desse problema.

A função de otimização objetivo é dada por (7.9):

$$\text{Min} \sum (R.I^2)^p \quad (7.9)$$



onde

- $(R.I^2)^\rho$  são perdas ativas nas fases  $a, b$  e  $c$ .
- $\rho$  são as fases  $a, b$  e  $c$ .

O conjunto de restrições utilizadas para esse problema está relacionado ao cálculo do fluxo de potência pelo algoritmo de Newton-Raphson. Conforme discutido em Ismail (2016), essas restrições podem ser dadas por (7.10), (7.11) e (7.12).

Sujeito a:

$$V_{min}^\rho \leq V_{i,k}^\rho \leq V_{m\bar{x}}^\rho \quad (7.10)$$

$$PI_i^\rho - PD_i^\rho - \sum P_{i,k}^\rho = 0 \quad (7.11)$$

$$QI_i^\rho - QD_i^\rho - \sum Q_{i,k}^\rho = 0 \quad (7.12)$$

onde

- $V_{min}^\rho$  é a magnitude da tensão mínima das três fases.
- $V_{m\bar{x}}^\rho$  é a magnitude máxima da tensão das três fases.
- $PI_i^\rho$  é a potência ativa injetada no nó  $i$  para as três fases.
- $PD_i^\rho$  é a potência ativa drenada para o nó  $i$  para as três fases.
- $QI_i^\rho$  é a potência reativa injetada no nó  $i$  para as três fases.
- $QD_i^\rho$  é a potência reativa drenada para o nó  $i$  para as três fases.
- $P_{i,k}^\rho$  é o fluxo de potência ativa que vai do nó  $i$  ao nó  $k$  das três fases.
- $Q_{i,k}^\rho$  é o fluxo de potência reativa que vai do nó  $i$  ao nó  $k$  para as três fases.

### 7.2.3.1 Previsão de geração de energia fotovoltaica

Uma RNA estimou a geração fotovoltaica conforme procedimento descrito em (Monteiro *et al* 2017). A estrutura da RNA é apresentada na Tabela 7.2. A previsão é realizada com base em dados meteorológicos coletados do Instituto Nacional de Pesquisas Espaciais (INPE) da cidade de Uberlândia-MG. A Figura 7.9 mostra uma comparação entre os dados medidos e os dados estimados. Portanto, a geração de pico fotovoltaico resultante determinada pela RNA foi de 1.269 kW.

Tabela 7.2 Estrutura da RNA

Arquitetura	Técnica	Nº de camadas	Neurônio oculto	Tempo de atraso aproveitado	Função de ativação/ camada oculta	Função de ativação/ camada de saída
NARX	Bayesian Regularization (BR)	2	10	2	Tangente-Sigmoide	Linear

Fonte: elaborada pelo autor.




Figura 7.9 Potência medida (W) e potência estimada (W) para 72 horas.

Fonte: elaborada pelo autor.

Como pode ser observado na Figura 7.9, o horizonte de previsão é de 72 horas. Inicialmente, a RNA foi treinada para estimar a geração fotovoltaica dependendo apenas da quantidade de informações de irradiação, ambiente e temperatura dos painéis solares que o usuário possui. A título de exemplo, foi calculada uma previsão de 72 horas e apresentada na Figura 7.9.

Foi utilizado um sistema real para coletar os dados de treinamento da RNA e depois dimensionar o sistema fotovoltaico para simulá-lo no alimentador de teste de 37 barras. O inversor de potência utilizado no sistema real é o PHB3000-NS cuja potência nominal é de 3.000 W. A tensão mínima MPPT (*maximum power point tracking*) é de 80 V. Devido à sua baixa tensão CC, esse inversor é capaz de operar em condições de baixa irradiação gerando baixa potência de saída no lado CA.

7.2.3.2 Dimensionamento do armazenamento de energia elétrica (AEE)

Os métodos utilizados para determinar o tamanho do AEE foram mostrados em Monteiro *et al.* (2016). A partir das análises desenvolvidas na seção anterior, a demanda de pico do sistema foi definida como 2.457 kW e a geração de pico fotovoltaico em 1.269 kW. À semelhança de Dufo-López, Lujano-Rojas e Bernal-Agustín (2014), o AEE foi limitado a 10% da diferença entre os valores nominais da geração fotovoltaica e da procura máxima. Caso contrário, os valores dimensionados seriam difíceis de alcançar.

Para melhor compreensão, a Tabela 7.3 apresenta um resumo do sistema considerado.

Tabela 7.3 Parâmetros do sistema de potência

Quantidade	kW	kWh
Demanda de pico do sistema	2.457	-
Geração de pico fotovoltaico	1.269	-
Capacidade de armazenamento de energia	110	54.000

Fonte: elaborada pelo autor.

Os perfis de demanda e fotovoltaico (estimado) do sistema são mostrados na Figura 7.10.




Figura 7.10 Demanda de energia versus geração fotovoltaica.

Fonte: elaborada pelo autor.

### 7.3 RESULTADOS E DISCUSSÕES

Para demonstrar a eficácia do algoritmo BPSO, o processo de otimização foi feito para três situações diferentes:

- Caso I: o desempenho do BPSO foi avaliado com a carga nominal, sem considerar a GD.
- Caso II: o segundo caso leva em consideração a geração fotovoltaica máxima nas barras 710, 711, 741; e o nível de carga de demanda nominal.
- Caso III: o terceiro caso considera a situação de maior geração fotovoltaica (barras 710, 711 e 741) e a demanda real do sistema no horário diurno considerado (esse cenário é próximo de um caso real).

Primeiramente, com exceção do caso III, todos os casos foram simulados considerando a injeção de ESS na barra 738 e depois não considerando a injeção de ESS em todos os casos. Quanto à modelagem das baterias, no cálculo do fluxo de potência elas foram inseridas como carga com fator de potência unitário ao carregar, e como gerador, ou seja, injetando potência ativa, com fator de potência unitário ao descarregar.

Como não estava disponível a informação referente ao valor ótimo para essa otimização, optou-se por testar o número de partículas até atingir 100 partículas. Cada uma das quantidades de partículas foi testada com 100 iterações. O primeiro caso foi usado para essa tarefa. A Figura 7.11 apresenta os melhores resultados alcançados para as quantidades de partículas. O computador utilizado para essas simulações foi um iMac com processador Intel Core i7 de 4 GHz e 32 GB de RAM.

Ao analisar a Figura 7.11, verifica-se que o algoritmo converge. Nos testes com 60 partículas para 100 iterações, o algoritmo alcançou seu melhor resultado geral das quantidades restantes, com exceção da otimização com 80 partículas, que obteve o mesmo resultado. Porém, para otimizar, deve-se levar em consideração que quanto mais partículas forem utilizadas, maior será o tempo computacional gasto. Assim, recomenda-se que, para esse caso, sejam utilizadas 60 partículas para 100 iterações. Dessa forma, essas quantidades foram utilizadas também para os outros três casos.




Figura 7.11 Convergência BPSO.

Fonte: elaborada pelo autor.

Pela Tabela 7.4, apresentada a seguir, nota-se que o algoritmo converge no valor de 0,032 pu, pois a média dos 10 resultados obtidos nas simulações para cada quantidade de partículas apresenta essa convergência.

Tabela 7.4 Partículas diversas, trechos abertos e perdas em pu –  $S_{base} = 1 \text{ MVA}$

Número de partículas	Topologia	Perdas (pu)	Média
10	5, 10, 19, 21, 28	0,03354	0,032775
20	10, 11, 12, 21, 42	0,03257	0,03245
30	5, 10, 11, 12, 20	0,03243	0,032515
40	5, 10, 11, 28, 42	0,0322	0,032235
50	5, 10, 11, 28, 42	0,0322	0,03223
60	5, 10, 12, 29, 42	0,03209	0,0322
70	5, 10, 15, 25, 28	0,03226	0,032345
80	5, 10, 15, 28, 37	0,03216	0,032205
90	5, 10, 11, 28, 42	0,0322	0,032235
100	10, 11, 25, 28, 37	0,03227	0,03222

Fonte: elaborada pelo autor.

A Tabela 7.5 apresenta a enumeração dada aos trechos de linha, enquanto a Tabela 7.4 mostra para cada quantidade de partículas, a sequência de trechos abertos que apresentaram os melhores resultados ao longo do processo de otimização. Na Tabela 7.5, as seções em *itálico* são as seções adicionais.

Tabela 7.5 Trechos e numeração atribuída

Trecho		Numeração atribuída	Trecho		Numeração atribuída
799	701	1	709	731	22
701	702	2	709	708	23
701	712	3	710	735	24
701	722	4	710	736	25
702	705	5	711	741	26
702	713	6	711	740	27
702	703	7	713	704	28
703	727	8	714	718	29
703	730	9	720	707	30
703	718	10	720	706	31
704	714	11	727	744	32
704	720	12	730	709	33
705	742	13	733	734	34
705	712	14	734	737	35
706	725	15	734	710	36
718	725	16	737	738	37
707	724	17	738	711	38
707	722	18	744	728	39
708	733	19	744	729	40
708	732	20	740	731	41
728	708	21	732	736	42

Fonte: elaborada pelo autor.


O segundo caso é uma situação em que o sistema está com maior nível de carga de demanda, maior geração fotovoltaica e AEE, conforme Tabela 7.3.

Para o terceiro caso, foi realizada uma simulação mais próxima de um caso real, e é aqui que a previsão da RNA se justifica. Para esse caso, conforme mostra a Figura 7.10, verifica-se que a maior penetração da GD ocorre no horário 14h, correspondendo a um nível de carga nominal 42,49% inferior ao observado em Monteiro *et al.* (2018). Porém, para efeito de comparação, foi considerado um nível de carga 50% menor. Como a geração da GD é superior à demanda de carga, neste estudo, não foi necessária a utilização do AEE.

Foram realizados quatro testes para avaliar a melhor posição do ESS no sistema, levando em consideração localizações concentradas e distribuídas. Para a topologia concentrada, no primeiro teste, o EES foi colocado no barramento 730. No segundo

teste, o ESS é colocado no barramento 738. Já para a topologia distribuída, o terceiro teste é realizado com a colocação do EES nos barramentos 701, 730, 738 e, na quarta prova, os trechos 724, 729 e 738 são escolhidos para receber o AEE. Segundo Monteiro *et al.* (2018), a melhor topologia foi encontrada no segundo caso, ou seja, as menores perdas sofridas pelo alimentador de teste tiveram o EES alojado na barra 738. A Tabela 7.7 mostra a comparação entre as perdas com e sem EES para a sequência de trechos abertos encontrados pela otimização BPSO com 60 partículas e 100 iterações.

A Figura 7.12 mostra o ESS operando durante 5 dias. Destaque que é considerado apenas o tempo em que o ESS está carregando ou descarregando, ou seja, foram retiradas as horas em que o ESS não é utilizado no modo carga-descarga. Assim, observe que nesse intervalo são realizados 5 ciclos de carga/descarga mostrando as perdas com e sem ESS. Cada ciclo representa um ciclo completo de carga-descarga por dia. Seguindo o processo descrito na Figura 7.2, um valor positivo (eixo esquerdo “y”) significa que o ESS está descarregando energia e um valor negativo significa que o ESS está no modo de carregamento. Por exemplo, entre 6 e 10 horas, mostra o ESS operando no modo de carregamento, ou seja, quando a demanda da rede está crescendo e atinge seu pico, e a geração fotovoltaica está diminuindo. Os valores no eixo “y” direito mostram o desempenho das perdas com e sem ESS.



**Figura 7.12** Ciclo diário do EES, perfil de perdas com e sem EES.

Fonte: elaborada pelo autor.

A Tabela 7.6 resume os resultados dos três estudos de caso.

**Tabela 7.6** Desempenho do BPSO para todos os estudos de caso – Sbase = 1 MVA

Base	Parâmetros	Estudo de caso 1	Estudo de caso 2	Estudo de caso 3
Sem reconfiguração	Perdas (pu)	0,03921	0,03921	0,0085
Com reconfiguração	Perdas (pu)	0,03209	0,00924	0,00445
	Chaves	5, 10, 12, 29, 42	12, 28, 31, 39, 42	3, 4, 11, 12, 23
	Perdas com ESS (pu)	0,02879	0,00882	–
	Chaves	5, 6, 10, 20, 29	11, 12, 15, 39, 42	-

Fonte: elaborada pelo autor.

Os resultados da Tabela 7.6 mostram que uma redução considerada de perdas foi alcançada pelo algoritmo BPSO. Para o caso 1, em comparação com o caso base, foi alcançada uma redução de perdas de 18,15% e, ao considerar o AEE, a redução aumentou para 26,57%. O estudo de caso 2 resultou em uma redução elevada de 76,43% e 77,50% quando se considera a AEE. Por fim, o estudo de caso 3 obteve redução de 47,64% nas perdas.

Uma vez estimada a geração fotovoltaica em 72 horas, o algoritmo proposto poderá ser usado entre essas horas. Porém, para um resultado de erro menor, recomenda-se um uso de 24 horas, uma vez que as condições meteorológicas são muito voláteis.

Não é uma tarefa fácil comparar esses resultados com outros resultados da literatura. Entretanto, isso pode ser feito com sistemas com mais de 30 barras. Os resultados do algoritmo BPSO apresentados neste capítulo são comparados de acordo com os mesmos estudos de caso investigados pelos artigos referenciados na *última* coluna. Como se pode ver na Tabela 7.7, a abordagem testada teve uma resposta melhor do que outras abordagens. A comparação feita leva em consideração duas otimizações multi-intervalos (Souza *et al.*, 2016a; Souza *et al.*, 2016b).

**Tabela 7.7** Comparação da literatura

Algoritmo	CLONALG	Copta-aiNet	Copt-aiNet / Opt-aiNet	IEPSO	BPSO sem armazenamento de energia	BPSO com armazenamento de energia
Barras	87	87	84	33	37	37
Caso comparado	1	1	1	1e3	1e3	1
Redução de perdas (%)	10,05	10,05	11,66	23,26 e 17,98	18,15 e 47,64	26,57
Referência	Souza <i>et al.</i> (2016a)	Souza <i>et al.</i> (2016b)	Souza; Romero; Franco (2015)	Napis <i>et al.</i> (2018)	Este trabalho	Este trabalho

Fonte: elaborada pelo autor.



## 7.4 CONCLUSÕES

O algoritmo BPSO demonstrou alta eficiência para a otimização de um sistema de distribuição de energia elétrica, aproximando-se da minimização de perdas. Existe um cenário de análise de big data, com 850.668 possibilidades topológicas, que dificulta a tarefa de encontrar uma boa topologia por meio de métodos iterativos de força bruta, e somente a IA pode lidar com tal problema.

A convergência do BPSO para esse caso retornou um valor de 0,032 pu, seguindo a média recuperada das simulações realizadas para o número de partículas e o número de iterações apresentadas. A melhor topologia encontrada precisou de 60 partículas e 100 iterações para ser descoberta. Três estudos de caso foram simulados para mostrar a vantagem do algoritmo BPSO.

Por fim, concluiu-se que, para processos de otimização, a utilização do BPSO na reconfiguração de sistemas de energia elétrica mostrou-se uma ferramenta viável e funcional.