

RECONFIGURAÇÃO ÓTIMA DE SISTEMAS DE DISTRIBUIÇÃO COM REPRESENTAÇÃO DAS INCERTEZAS DA CARGA ATRAVÉS DE FLUXO DE POTÊNCIA PROBABILÍSTICO

Felipe da Silva Seta

Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n - Campus Universitário, Bairro São Pedro
felipe.seta@engenharia.ufjf.br

**Leonardo Willer de Oliveira, Ivo Chaves da Silva Junior, Flávio Vanderson Gomes, Bruno
Henriques Dias**

Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n - Campus Universitário, Bairro São Pedro
leonardo.willer@edu.ufjf.br, ivo.junior@edu.ufjf.br, flavio.gomes@edu.ufjf.br,
bhdias@yahoo.com.br

RESUMO

Este artigo propõe uma metodologia para solução do problema de reconfiguração ótima de sistemas de distribuição de energia elétrica, visando minimizar o valor esperado de perdas de energia considerando-se a natureza probabilística da carga. A metodologia proposta é baseada na técnica meta-heurística Sistema Imunológico Artificial. Um fluxo de potência probabilístico que considera a incerteza na demanda das barras do sistema é utilizado. A demanda nas barras é modelada através de funções de distribuição de probabilidade normal. A metodologia proposta utiliza curvas de cargas diárias típicas das barras do sistema. O fluxo de potência proposto emprega o método de simulação de Monte Carlo para gerar diversos cenários de demanda do sistema de distribuição. O objetivo principal é avaliar o impacto de se representar o modelo probabilístico da demanda na configuração ótima da rede elétrica, com relação aos modelos tradicionais determinísticos. O algoritmo proposto é testado em um sistema conhecido na literatura.

PALAVRAS CHAVE. reconfiguração ótima. sistema imunológico artificial. fluxo de potência probabilístico.

ABSTRACT

This paper proposes a methodology to solve the problem of optimal reconfiguration of distribution systems of electric power, in order to minimize the expected value of energy losses considering the probabilistic nature of the load. The proposed methodology is based in the technical meta-heuristic artificial immune system. A probabilistic power flow that considers the uncertainty in the demand of the system buses is used. The demand in the buses is modeled through functions of normal probability distribution. The proposed methodology uses daily load curves from the buses of the system. The proposed power flow uses the Monte Carlo simulation method to generate multiple demand scenarios of the distribution system. The main objective is to evaluate the impact of the probabilistic model on the optimal network configuration in comparison to traditional deterministic models. The developed algorithm is tested in a system known in the literature.

KEYWORDS. optimal reconfiguration. artificial immune system. probabilistic power flow.

1. Introdução

Atualmente, verifica-se uma busca constante por eficiência em qualquer setor produtivo. Este aspecto também é almejado no setor de distribuição de energia elétrica. Dentro desse contexto, a minimização de perdas técnicas em sistemas de distribuição de energia elétrica (SDE) é importante, já que segundo Gonen (1986) este fator é um dos que mais contribui para o aumento dos custos operacionais do sistema. Diferentes alternativas podem ser adotadas por parte das distribuidoras visando à redução das perdas técnicas. Uma alternativa amplamente explorada na literatura é a reconfiguração da rede de distribuição, alguns estudos que podemos citar relacionados a esta técnica são: Resende et al. (2011), Torres-Jimenez et al. (2010) e Oliveira et al. (2010). Nesses estudos, o fluxo de potência utilizado para avaliação de cada solução candidata é de natureza determinística, o que de acordo com Monticelli e Garcia (2004) é devido principalmente ao fato de que as variáveis de controle são modeladas de forma fixa e não permitem serem variadas durante o processo de cálculo.

Sabe-se, no entanto, segundo Wang e Alvarado (1992) e Borkowska (1974), que nos SDE reais a demanda nas barras possui um elevado grau de incerteza devido principalmente a erros de medição e constante variação da carga. Por esses fatores, torna-se necessário introduzir o fenômeno da aleatoriedade no fluxo de potência para análises em SDE. Essa aleatoriedade pode ser alcançada em termos de uma faixa de valores de demanda junto com uma probabilidade associada. Em Borkowska (1974) é empregado o modelo do fluxo de potência DC que considera as injeções de potência nas barras de carga como variáveis aleatórias e encontra as funções de densidade de probabilidade dos fluxos de potência em todas as linhas do sistema. Já em Allan (1981) uma técnica de convolução discreta no domínio da frequência é empregada para obter a solução do fluxo de potência probabilístico, é empregada a transformada rápida de Fourier para linearizar as equações de fluxo de potência.

A reconfiguração ótima de SDE, que de acordo com Sarfi et al. (1994), consiste na determinação de uma topologia radial e conexa da rede, através da definição dos estados (aberto ou fechado) das chaves manobráveis acopladas aos circuitos de distribuição. Esta topologia, segundo Kalantar et al. (2006), otimiza um determinado índice do sistema, como a redução das perdas técnicas, atendendo as restrições operacionais. Devido a essas características, a reconfiguração ótima de SDE visando minimizar perdas técnicas nos conduz a um problema de natureza não linear inteira mista, cuja região de solução é não convexa e a natureza combinatorial é elevada. A garantia da melhor solução para este tipo de problema somente pode ser dada a partir da investigação de todas as combinações possíveis, o que é computacionalmente inviável para os requisitos dos SDE. Baseado nessas características, este problema é propício para aplicação de técnicas meta-heurísticas. Tais técnicas permitem uma maior aproximação da melhor solução possível, ou solução ótima global, através de uma varredura eficiente do espaço de busca, com tempos viáveis de processamento. Em Resende et al. (2011) é proposta a reconfiguração de SDE visando à minimização das perdas técnicas através também da meta-heurística sistema imunológico artificial só que com a utilização de um fluxo de potência determinístico. Em Khoa e Phan (2006) é proposto um algoritmo que se baseia na meta-heurística colônia de formigas para a reconfiguração de SDE com o objetivo também de minimização de perdas técnicas.

Seguindo essa linha de pesquisa, o presente trabalho propõe a aplicação da técnica meta-heurística bio-inspirada intitulada Sistemas Imunológicos Artificiais (SIA) ao problema de reconfiguração ótima de SDE utilizando fluxo de potência probabilístico visando, já que considera a incerteza na demanda, a minimização do valor esperado da perda de energia diária. De acordo com Silva e Zuben (2002) e Seta et al. (2013), por apresentar mecanismos evolutivos importantes para pesquisar o espaço de busca, esta técnica produz soluções factíveis de boa qualidade e com tempos aceitáveis para os requisitos dos SDE. A metodologia proposta contempla aspectos importantes como a representação de diferentes níveis de carga do sistema e a incerteza na demanda através da geração de diversos cenários de carga. O desenvolvimento deste trabalho é motivado pela complexidade deste problema. A escolha da técnica SIA foi feita a partir do ineditismo de sua aplicação ao problema de reconfiguração probabilística, e de sua

utilização bem sucedida nos problemas de reconfiguração determinística em Resende et al. (2011) e de alocação ótima de geração distribuída em SDE em Seta et al. (2013). A metodologia proposta é validada em um sistema conhecido da literatura.

2. Fluxo de Potência Probabilístico Proposto

O algoritmo de fluxo de potência probabilístico proposto neste artigo baseia-se no método de simulação de Monte Carlo que serve para gerar possíveis cenários de carga do sistema de distribuição em estudo. Uma vez gerado um possível cenário de carga do sistema é necessário calcular um fluxo de potência determinístico para determinar as condições de regime permanente do sistema. O fluxograma da figura 1 apresenta os passos do algoritmo proposto que são descritos na seqüência.

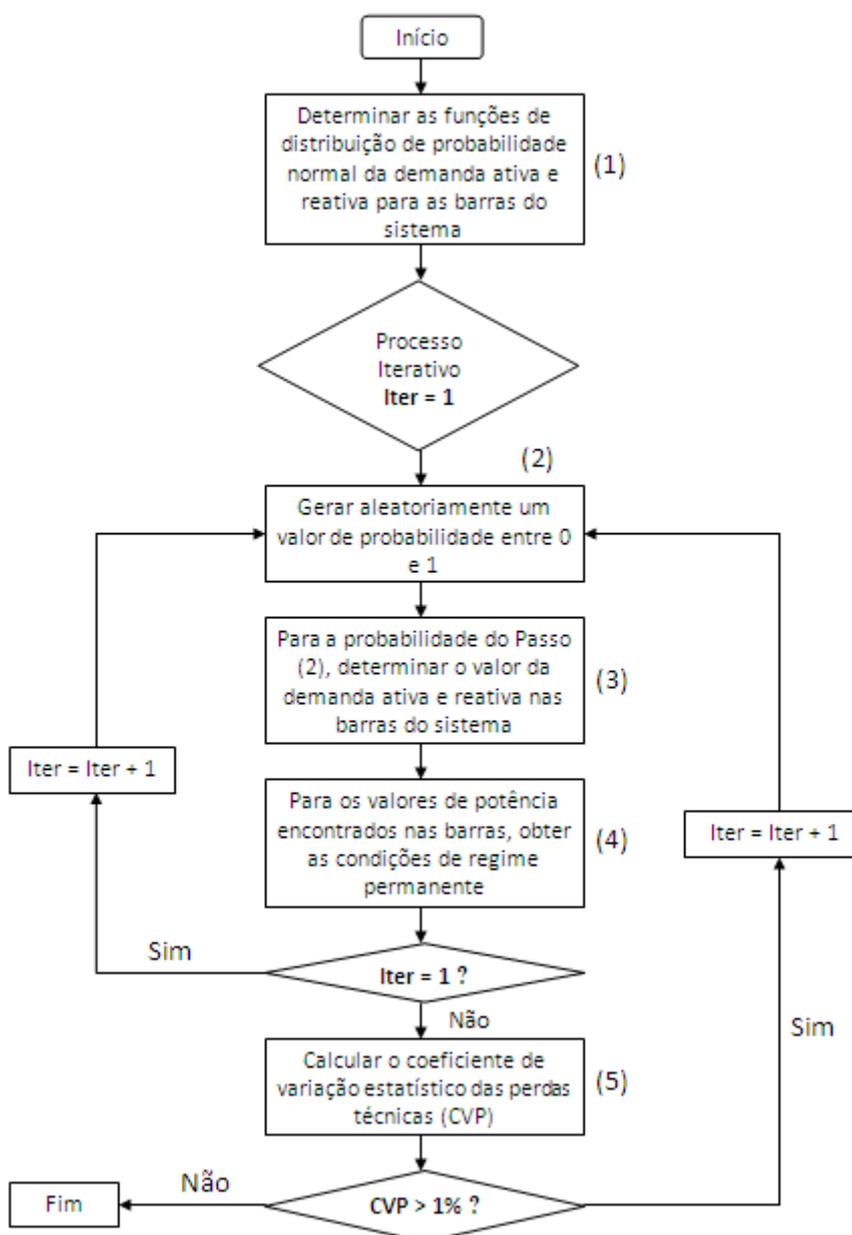


Figura 1 - Fluxograma do algoritmo proposto

Passo (1): Neste passo são determinadas as funções de distribuição de probabilidade normal da demanda ativa e reativa para cada barra do sistema. Este passo é realizado para cada nível de carregamento existente, como é considerado curvas de carga diária, serão 24 níveis de carregamento um para cada hora do dia. Este passo é realizado baseado na curva média e desvio padrão da demanda ativa e reativa de cada barra do sistema, a curva média e de desvio padrão são estabelecidas de acordo com Pareja (2009). A função de distribuição de probabilidade normal para a demanda em cada barra do sistema pode ser representada de acordo com a equação (1).

$$F_L(L) = \frac{1}{\sigma\sqrt{2\pi}} \int_L^{\infty} e^{-\frac{(L-\bar{L})^2}{2\sigma^2}} dL \quad (1)$$

Em que:

- \bar{L} - Valor médio da demanda;
- σ - Desvio padrão da demanda.

Passo (2): Neste passo é gerado aleatoriamente um valor de probabilidade entre 0 e 1. Este passo é o primeiro do processo iterativo e dá início a simulação de Monte Carlo. De acordo com Law e Kelton (2000) e Zapata (2005) o método de simulação de Monte Carlo é o processo de geração de números aleatórios empregando qualquer distribuição de probabilidade, no caso desse artigo a normal, para avaliar de forma numérica e indireta um modelo matemático que permite estimar o comportamento de um sistema. Os números aleatórios gerados devem cumprir as propriedades de uniformidade e independência.

Passo (3): Neste passo, para a probabilidade encontrada no passo (2) é determinado o valor da demanda de potência ativa e reativa em cada barra do sistema. Este passo dá continuidade ao método de simulação de Monte Carlo. Uma vez determinado um número aleatório U , se pode gerar uma observação da variável aleatória de interesse de acordo com a equação (2).

$$L = F_L^{-1}(U) \quad (2)$$

Em que:

- L - Observação da variável demanda para a probabilidade U ;
- U - Número aleatório uniforme que representa a probabilidade.

Passo (4): Neste passo, para os valores de potência encontrados em cada barra, se obtêm as condições de regime permanente do sistema e conseqüentemente o valor das perdas técnicas através do cálculo do fluxo de potência determinístico. O fluxo de potência determinístico utilizado é um fluxo de potência não - linear baseado no método iterativo de Newton Raphson. A descrição deste método pode ser encontrada em Monticelli (1983).

Passo (5): Neste passo, é calculado o coeficiente de variação estatístico das perdas técnicas. Este é um dos procedimentos mais conhecidos utilizado como critério de parada de uma simulação de Monte Carlo. Quando o coeficiente de variação estatístico da variável de interesse, no caso as perdas técnicas, é menor que um valor preestabelecido o processo de simulação de Monte Carlo para. Neste artigo, quando o coeficiente de variação estatístico das perdas técnicas for menor que 1% o processo de simulação de Monte Carlo para. O coeficiente de variação estatístico das perdas técnicas deve ser calculado a partir da segunda iteração e de acordo com Zapata (2005) pode ser determinado de acordo com a equação (3).

$$CVP = \frac{\sigma}{\mu\sqrt{Iter}} \quad (3)$$

Em que:

- μ - Valor médio das perdas técnicas;
- σ - Desvio Padrão das perdas técnicas;
- Iter* - Número da Iteração.

O algoritmo proposto na figura 1 é repetido para cada nível de carregamento existente. Como está se trabalhando com curvas de carga diária, ele será repetido 24 vezes, uma para cada hora do dia. Com isso, para cada hora do dia será gerado uma quantidade de cenários de carga igual ao número da iteração atingida até a convergência do método. Para cada cenário gerado, é calculado um fluxo de potência determinístico e armazenado as perdas técnicas daquele cenário ou daquela iteração. Depois, é calculado o valor esperado das perdas técnicas para cada hora de acordo com a equação (4).

$$E(Perdas) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} X e^{-0.5\left[\frac{X-\mu}{\sigma}\right]^2} dX \quad (4)$$

Em que:

- $E(perdas)$ - Valor esperado das perdas técnicas para cada nível de carregamento (hora);
- μ - Média Aritmética das perdas técnicas geradas para cada hora;
- σ - Desvio padrão das perdas técnicas geradas para cada hora;
- X - Variável aleatória contínua em estudo (Perdas técnicas).

Como cada nível de carregamento existente corresponde à uma hora do dia, a perda de energia em um determinado nível é igual à perda de potência ativa (perda técnica) na hora correspondente. Conseqüentemente, o valor esperado da perda de energia em um nível é igual ao valor esperado da perda técnica na respectiva hora. Sendo assim, pode-se estabelecer que o valor esperado da perda de energia diária é calculado de acordo com a equação (5).

$$E(P_{energiadiária}) = \sum_{i=1}^{24} E_i(Perdas) \quad (5)$$

Em que:

- $E(P_{energiadiária})$ - Valor esperado da perda de energia diária;
- $E_i(Perdas)$ - Valor esperado da perda técnica no nível i .

De acordo com a equação (5), verifica-se que o valor esperado da perda de energia diária é igual à soma dos valores esperados das perdas técnicas ou perdas de energia em cada nível. O valor esperado da perda de energia diária fornecido pela equação (5) é a função objetivo (FOB) a ser minimizada no problema de reconfiguração ótima de SDE via sistemas imunológicos artificiais utilizando fluxo de potência probabilístico.

Destaca-se que a configuração ótima proposta é única para todos os níveis de carga considerados. Em outras palavras, a solução do problema de reconfiguração é a mesma para todas as horas do dia, não havendo, portanto, chaveamentos entre os níveis. Logo, a solução final é factível para todas as horas, pois se uma determinada solução candidata não for factível para pelo menos um nível, esta solução tem sua função objetivo penalizada, sendo, portanto, descartada do processo de otimização.

Conforme descrito anteriormente, como o processo de reconfiguração ótima

considerando a natureza probabilística da carga contempla diferentes níveis de carregamento, a FOB inclui os horários de pico associados às condições de carga pesada, bem como os horários de carga leve. No entanto, a metodologia proposta não trata a carga pesada de forma diferenciada dos demais níveis. Para isto, a função objetivo deveria ser associada à minimização do custo do valor esperado da perda, ao invés do valor esperado da perda, pois desta forma um custo unitário diferenciado poderia ser atribuído ao valor da perda do nível de carga pesada. No entanto, este aspecto pode ser facilmente incorporado na metodologia apresentada neste artigo, conforme incluído nas propostas de trabalhos futuros.

3. O Algoritmo Clonalg

O algoritmo para reconfiguração ótima de SDE via Sistemas Imunológicos Artificiais (SIA) utilizando Fluxo de Potência Probabilístico tem como base um algoritmo de seleção clonal (Clonalg), proposto em Silva e Zuben (2002). Esse método é inspirado no sistema imunológico natural adaptativo dos animais vertebrados, em que os anticorpos produzidos no organismo são responsáveis pelo combate aos agentes patológicos ou antígenos. A complementaridade entre os anticorpos e o antígeno define a afinidade de ligação entre os mesmos. Quando a ligação é boa, ocorre a ativação dos anticorpos. A partir daí, desenvolve-se a maturação da afinidade, onde mecanismos como seleção clonal, clonagem, hipermutação somática, seleção negativa e edição de receptores possibilitam ao organismo produzir variedades de anticorpos com alta afinidade ao antígeno. Seguindo essa estratégia e mecanismo de atuação, o presente trabalho faz uma adequação das características do sistema imunológico adaptativo natural ao problema de otimização a ser solucionado. Esta adequação é análoga à efetuada em Seta et al. (2013) para o problema de alocação ótima de geração distribuída em SDE. O fluxograma da figura 2, utilizado em Seta et al. (2013), apresenta os passos do algoritmo proposto que são descritos na seqüência.

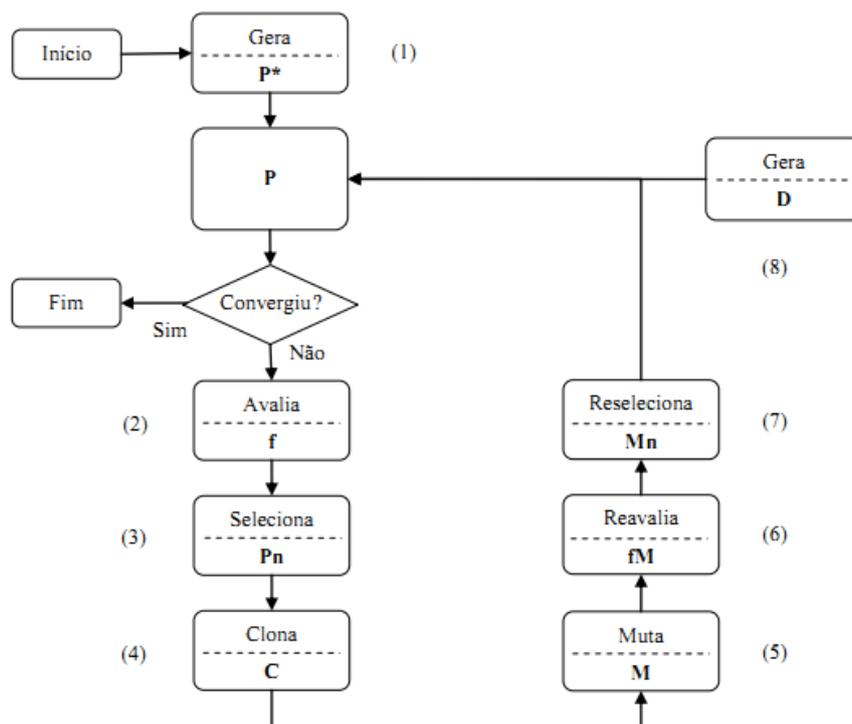


Figura 2 - Fluxograma do algoritmo proposto

Passo (1): Geração do conjunto inicial de anticorpos P^* : cada anticorpo corresponde a uma solução candidata para o problema de reconfiguração. O repertório P^* contém N anticorpos. Destaca-se que P^* representa uma matriz $[N \times L]$, em que L é o número de atributos de cada

anticorpo. A geração do repertório inicial inclui apenas topologias radiais e conexas. Para isso, é utilizado um algoritmo baseado em teoria de grafos conforme apresentado em Golgbarg e Luna (2005).

Passo (2): Avaliação da afinidade f dos anticorpos de P : a afinidade de cada anticorpo é dada pelo inverso da função objetivo formulada pela equação (5), calculada através do algoritmo de fluxo de potência probabilístico desenvolvido no item 2 deste artigo.

Passo (3): Seleção dos anticorpos para clonagem: são selecionados n anticorpos distintos de P com maior afinidade (menores valores da função objetivo) para compor o conjunto P_n .

Passo (4): Clonagem dos anticorpos de P_n : são clonados os anticorpos do conjunto P_n , formando o conjunto C , sendo o número de clones proporcional a afinidade normalizada dos anticorpos de P_n .

Passo (5): Hipermutação somática dos anticorpos de C : os anticorpos de C são submetidos ao processo de hipermutação somática formando o conjunto de mutantes M . A probabilidade de mutação de um anticorpo é inversamente proporcional à sua afinidade normalizada.

Passo (6): Avaliação da afinidade f_M dos anticorpos de M conforme Passo (2).

Passo (7): Seleção dos anticorpos de M para substituição em P : são selecionados n anticorpos distintos com maior afinidade (menores funções objetivo) formando o conjunto M_n . Estes anticorpos substituem os n anticorpos com menor afinidade de P .

Passo (8): Edição de receptores: são gerados de forma aleatória d novos anticorpos que constituem o conjunto D . Estes anticorpos substituem os d anticorpos de P com menor afinidade, para inserção de diversidade no conjunto P . É utilizada neste passo a mesma estratégia de geração de anticorpos do passo (1). Este mecanismo de atuação visa evitar a convergência prematura do algoritmo em soluções sub-ótimas, conduzindo o processo de otimização para novas regiões do espaço de busca.

Durante os processos de avaliação das afinidades, os anticorpos que não atendem às restrições operacionais da rede elétrica e de seus componentes são descartados do processo de seleção clonal. Ou seja, estes anticorpos não geram clones. Esse processo caracteriza o mecanismo de seleção negativa do sistema imune nato, em que anticorpos que reconhecem as células do próprio corpo, ou antígenos próprios, são eliminados para evitar um ataque ao próprio organismo.

O número de atributos de cada anticorpo (L), no passo (1), é igual ao número de chaves manobráveis do sistema. Cada atributo de um anticorpo representa o estado de uma chave. Para chave aberta o atributo recebe o valor 0 e para chave fechada o atributo recebe o valor 1. A codificação apresentada na tabela 1 é utilizada para aplicação ao problema de reconfiguração ótima de SDE utilizando fluxo de potência probabilístico visando minimização do valor esperado da perda de energia diária através da metodologia de otimização proposta.

Tabela 1 - Codificação do problema de reconfiguração ótima utilizando a técnica meta-heurística SIA

SIA	Correspondência no problema de reconfiguração ótima de SDE
Anticorpo	Configuração da rede.
Atributo do anticorpo	Estado da chave (0 ou 1).
Afinidade	Inversamente proporcional ao valor da função objetivo formulada na equação (5).

O número de clones N_c gerados no processo de clonagem do passo (4) para cada anticorpo selecionado é dado pela equação (6).

$$N_c(i) = \text{round} \left(\frac{c}{fP_n^*(i)} \right) \quad (6)$$

Em que:

- $N_c(i)$ - Número de clones do anticorpo i ;
- $\text{round}(\cdot)$ - Operador que arredonda para o valor inteiro mais próximo;
- c - Parâmetro que controla o processo de clonagem;
- $fPn^*(i)$ - Afinidade normalizada do anticorpo i .

A afinidade normalizada do anticorpo i ($fPn^*(i)$) é calculada em função de sua afinidade $fPn(i)$, dada pelo valor inverso da função objetivo formulada na equação (5), conforme equação (7).

$$fPn^*(i) = \frac{1}{\left\{ 1 + e^{\left[-\left(\frac{fPn(i) - \overline{fPn}}{\delta^*} \right) \right]} \right\}} \quad (7)$$

Em que:

- \overline{fPn} - Média aritmética das afinidades dos anticorpos selecionados;
- δ^* - Desvio padrão das afinidades dos anticorpos selecionados.

A probabilidade de mutação de um anticorpo i é calculada através da equação (8).

$$p(i) = e^{\left(\frac{-h}{fC^*(i)} \right)} \quad (8)$$

Em que:

- $p(i)$ - Probabilidade de mutação do anticorpo i ;
- h - Parâmetro que controla o processo de hipermutação somática;
- $fC^*(i)$ - Afinidade normalizada do anticorpo i clonado.

O cálculo do número de clones na equação (6) e a probabilidade de mutação de um anticorpo na equação (8) consistem em alterações no algoritmo Clonalg originalmente proposto em Silva e Zuben (2002), conforme sugerido em Resende et al. (2011), para aprimoramento do processo de otimização. A normalização do tipo sigmoidal da equação (7) conforme Resende et al. (2011) permitiu obter uma distribuição mais adequada dos valores de afinidade dentro da faixa normalizada. A tabela 2 apresenta os parâmetros do algoritmo Clonalg utilizados no presente trabalho.

Tabela 2 - Parâmetros do algoritmo proposto

Parâmetro	N	c	h	n	d
Valor	2*NBAR	3,5	0,075	0,06*N	0,03*N

Em que NBAR é o número total de barras do sistema em estudo. A definição adequada dos parâmetros mostrados na tabela 2 é imprescindível para o bom desempenho do método. No presente trabalho, os valores dos parâmetros foram especificados a partir de testes empíricos. O critério de convergência utilizado é o número máximo de gerações igual a 50.

4. Estudo de Caso

Nesta seção, são apresentados os resultados obtidos através da aplicação dos algoritmos propostos. Para tanto, o sistema de 33 barras da literatura proposto em Baran e Wu (1989) é utilizado. Suas características são: 12,66 kV de tensão, carga total de 3.715,0 kW e 2.300,0 kVAr, 37 linhas que incluem 5 chaves de interconexão (NA) (S33–S37), sendo sua topologia radial original mostrada na figura 3.

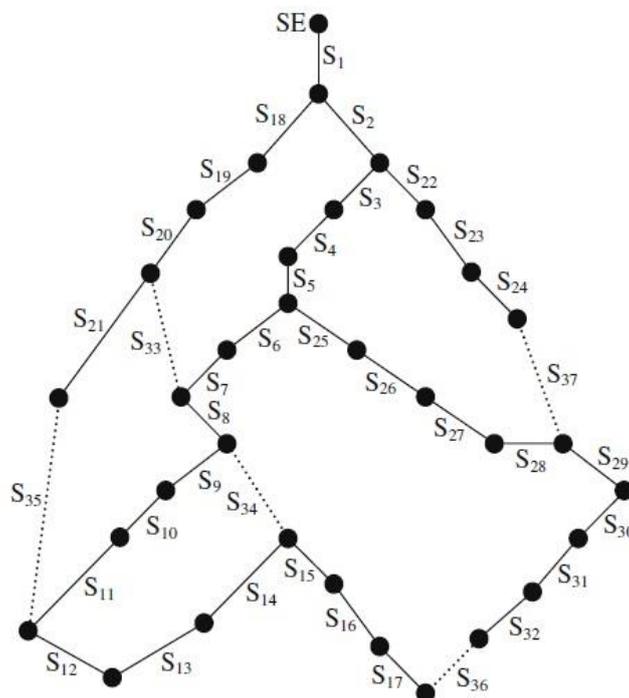


Figura 3 - Topologia original do sistema de 33 barras proposto em Baran e Wu (1989)

A tabela 3 apresenta os resultados obtidos por outros métodos aplicados ao problema de reconfiguração de SDE do sistema de 33 barras em estudo.

Tabela 3 - Resultados obtidos por outros métodos

Configuração	Inicial	Gomes et al.(2005), Oliveira et al. (2010) e Resende et al. (2011)
Chaves Abertas	33, 34, 35, 36, 37	7, 9, 14, 32, 37
Perdas (kW)	202,68	139,55

Destaca-se, que os resultados apresentados na tabela 3 para outros métodos utilizam todos, sem exceção, fluxo de potência convencional determinístico para avaliação das soluções candidatas. A tabela 4 apresenta os resultados obtidos pela metodologia apresentada neste trabalho, que utiliza fluxo de potência probabilístico para avaliação das soluções candidatas.

Tabela 4 - Resultados obtidos pela metodologia proposta

Configuração	Inicial	Metodologia Proposta
Chaves Abertas	33, 34, 35, 36, 37	7, 9, 14, 32, 37
$E(P_{\text{energiadiária}})$ (kWh)	5.127,90	3.508,70

Como se pode observar pela tabela 4, a solução obtida pela metodologia proposta é a mesma obtida pelos métodos apresentados na tabela 3. Estes resultados demonstram que mesmo utilizando a abordagem probabilística da carga, a configuração de chaves abertas não se alterou.

A avaliação da robustez da metodologia proposta através de diversas execuções é importante em se tratando de um método de natureza probabilística como o SIA. Foram realizadas 10 execuções da metodologia proposta, e nas 10 execuções a solução de chaves abertas apresentada na tabela 4 se confirmou. Obviamente, que o valor esperado da perda de energia diária não foi o mesmo nas 10 execuções já que utiliza-se um fluxo de potência probabilístico para avaliação das soluções candidatas, mas todos são próximos do valor apresentado na tabela 4. Este comportamento comprova a consistência do método. No entanto, cabe destacar que não se pode garantir a mesma solução em todas as execuções, devido à natureza probabilística do processo de busca. Ainda assim, a manutenção da solução observada para o sistema utilizado indica uma tendência favorável, que aponta para a robustez da técnica SIA aplicada ao problema.

Em todas as 10 execuções da metodologia proposta a melhor solução foi obtida em 50 gerações, número este que é o máximo de gerações do critério de convergência. Isto já era esperado, pois como utiliza-se um fluxo de potência probabilístico para avaliação das soluções candidatas, dificilmente se encontrará duas soluções com o mesmo valor esperado de perda de energia diária, mesmo tendo essas duas soluções a mesma configuração de chaves abertas.

O tempo médio de execução do algoritmo de otimização proposto para este caso de estudo, calculado através da média aritmética dos tempos requeridos por cada uma das 10 execuções efetuadas para análise de robustez, foi de 873,6 segundos. Destaca-se que este tempo, requerido devido à abordagem probabilística da carga que inclui diferentes cenários de carga, pode ser reduzido através de ajustes nos passos do algoritmo proposto. Esta redução será tratada em trabalhos futuros, tendo em vista a robustez e a boa qualidade da solução apresentada no presente artigo.

5. Conclusão

A metodologia proposta no presente trabalho para reconfiguração ótima de SDE utilizando fluxo de potência probabilístico permitiu avaliar o impacto da abordagem probabilística da carga na reconfiguração de SDE. Destaca-se que esta metodologia permite tratar de forma adequada as incertezas associadas à demanda do sistema, bem como suas curvas diárias de carga. O estudo de caso realizado para avaliar o desempenho do algoritmo proposto indicou que a abordagem probabilística da carga não alterou a configuração de chaves abertas encontrados por outros métodos que utilizam fluxo de potência convencional determinístico. No entanto, esta conclusão não pode ser, a princípio, estendida para todos os casos, envolvendo outros sistemas, o que deverá ser investigado em trabalhos futuros. A partir da robustez do algoritmo proposto, confirmada pela manutenção da configuração ótima através de diversas execuções, e da qualidade da solução encontrada, confirmada pela literatura especializada, pode-se concluir que a metodologia proposta é promissora para a otimização e o planejamento de redes de distribuição. Destaca-se que a meta-heurística Sistemas Imunológicos Artificiais é ainda inexplorada na literatura para a resolução do problema de reconfiguração ótima de SDE considerando-se a natureza probabilística da carga. Um aspecto importante a ser contemplado em trabalhos futuros é a minimização do custo total do valor esperado da perda de energia, com custos unitários diferenciados entre os níveis de carregamento, a fim de representar o maior impacto para o sistema da perda de energia na carga pesada. Por fim, a redução do tempo computacional do algoritmo proposto também deverá ser tratada em futuros desenvolvimentos.

Agradecimentos

Os autores do presente trabalho gostariam de agradecer ao apoio da CAPES, CNPq, FAPEMIG, INERGE, e ao apoio do grupo de pesquisa 'Otimização Heurística e Bioinspirada', da UFJF.

Referências

- Allan, R. N.; Leite da Silva, A. M. L.** Probabilistic load flow using multilinearizations. *IEE Proc. C: Generation, Distribution, London*, v. 128, n. 5, p. 280 - 287, Sept., 1981.
- Baran, M. E. and Wu, F. F.** "Network reconfiguration in distribution systems for loss reduction and load balancing," *IEEE Trans. Power Delivery*, vol. 4, no. 2, pp. 1401–1407, Apr. 1989.
- Borkowska, B.** Probabilistic load flow. *IEEE Trans. On Power Systems*, New York, v. PAS - 93, n. 3, p. 752 - 755, May/June, 1974.
- Golgbarg, M. C and Luna, H. P. L** *Otimização Combinatória e Programação Linear: modelos e algoritmos*. -2.ed.- Rio de Janeiro: Elsevier, 2005.
- Gomes, F. V.; Carneiro Junior, S.; Pereira, J. R. L; Vinagre, M. P; Garcia, P. A. N and Araújo, L. R** "A new heuristic reconfiguration algorithm for large distribution systems," *IEEE Trans. Power Systems*, vol. 20, no. 3, pp. 1373–1378, Aug. 2005.
- Gonen, .T** *Electric Power Distribution System Engineering*. -1.ed.- New York: McGraw Hill, 1986.
- Kalantar, M.; Dashti M. and Dashti M.** "Combination of network reconfiguration and capacitor placement for loss reduction in distribution system with based genetic algorithm", in *Proc. 41st International Universities Power Engineering Conference (UPEC '06)*, Newcastle upon Tyne, UK, 2006, vol. 1, pp. 308-312.
- Khoa, T. Q. D. and Phan, B. T. T.** "Ant colony search-based loss minimum for reconfiguration of distribution systems," in *Proc. IEEE Power India Conference*, New Delhi, India, 2006, p. 6.
- Law, A. M.; Kelton, W. D.** *Simulation modeling & analysis*. New York: McGraw - Hill. 2000. 745 p.
- Monticelli, A.** (1983). *Fluxo de carga em redes de energia elétrica*, São Paulo: Edgar Blücher.
- Monticelli, A.; Garcia, A.** *Introdução a sistema de energia elétrica*. Campinas: Unicamp. 2004. 148 p.
- Oliveira, L. W.; Oliveira, E. J.; Carneiro Junior, S.; Pereira, J. L. R.; Costa, J. S. and Silva Junior, I. C.** "Optimal reconfiguration and capacitor allocation in radial distribution systems for energy losses minimization," *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 8, pp. 840–848, Oct. 2010.
- Pareja, L. A. G** *Fluxo de Potência em Redes de Distribuição de Energia Elétrica Considerando Incertezas*, Tese de Doutorado, Ilha Solteira - SP, Junho de 2009.
- Resende, P. V. C; Oliveira, L. W.; Oliveira, E. J.; Gomes, F. V; Oliveira, A. R.; Variz, A. M and Silva Junior. I. C** " Reconfiguração de Sistemas de Distribuição de Energia Elétrica Via Sistemas Imunológicos Artificiais " in *9th Latin - American Congress on Electricity Generation and Transmission (CLAGTEE) 2011*.
- Sarfi, R. J.; Salama, M. M. A. and Chikhani, A. Y.** (1994). A survey of the state of the art in distribution system reconfiguration for system loss reduction. *Electric Power Systems Res.*, Vol. XXXI, No. 1, pp. 61 - 70.
- Seta, F. S.; Oliveira, L. W.; Dias, B. H.; Gomes, F. V and Junior, I. C. S** " Alocação Ótima de Geração Distribuída em Sistemas de Distribuição via Sistemas Imunológicos Artificiais e Fluxo de Potência Ótimo " *Décimo Quinto Encontro Regional Ibero - americano do CIGRÉ*, Maio de 2013, Foz do Iguaçu - PR, Brasil.
- Silva, L. N. C and Zuben, F. J. V** "Learning and optimization using the clonal selection principle," *IEEE Trans. Evolutionary Computation*, vol. 6, no. 3, pp. 239–251, Aug. 2002.

Torres-Jimenez, J.; Guardado, J. L.; Rivas, F.; Maximov, S. and Melgoza, E. “Reconfiguration of power distribution systems using genetic algorithms and spanning trees”, in *Electronics, Robotics and Automotive Mechanics Conference (CERMA)*, Cuernavaca, Morelos, Mexico, 2010, pp. 779-784.

Wang, Z.; Alvarado, F. L. Interval arithmetic in power flow analysis. *IEEE Trans. On Power Systems*, New York, v. 7, n. 3, p. 1341 - 1349, Aug., 1992.

Zapata, C. J. *Análisis probabilistic y simulación Colombia*: Universidade Tecnologica de Pereira, Pereira. 2005.