

ALGORITMO IMUNOLÓGICO ARTIFICIAL OPT-AINET APLICADO A RECONFIGURAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO CONSIDERANDO DEMANDAS VARIÁVEIS

Simone S. F. Souza

Departamento de Engenharia Elétrica, UNESP – Univ. Estadual Paulista
Av. Brasil, 56, Centro, 15385-000, Ilha Solteira, SP, Brasil
simonefrutuoso.mat@gmail.com

Ruben Romero

Departamento de Engenharia Elétrica, UNESP – Univ. Estadual Paulista
Av. Brasil, 56, Centro, 15385-000, Ilha Solteira, SP, Brasil
ruben@dee.feis.unesp.br

RESUMO

Neste artigo apresenta-se uma aplicação do algoritmo imunológico artificial Opt-aiNet (Artificial Immune Network for Optimization) para resolver o problema de reconfiguração de sistemas de distribuição com demandas variáveis não uniformes. O algoritmo Opt-aiNet é uma técnica de otimização eficiente inspirada na rede imunológica (aiNet), que por sua vez reproduz computacionalmente as principais propriedades e funcionalidades do sistema imunológico biológico. O problema de reconfiguração de sistemas de distribuição com demandas variáveis não uniformes é um problema complexo, que tem por objetivo encontrar uma única topologia radial que satisfaça os requisitos para operar em todos os níveis de demanda em um sistema de distribuição, visando minimizar os custos de perdas de energia ao longo de um período de operação. Neste trabalho são apresentados resultados utilizando os sistemas elétricos de distribuição de 33, 84 e 136 barras. Os resultados comprovam a robustez e eficiência do método proposto.

PALAVRAS CHAVE. Reconfiguração de Sistemas de Distribuição, Demandas Variáveis, Sistemas Imunológicos Artificiais, Opt-aiNet.

EN - PO na Área de Energia

ABSTRACT

This paper presents an application of artificial immune algorithm Opt-aiNet (Artificial Immune Network for Optimization) to solve the distribution systems reconfiguration problem with non-uniform variable demands. The Opt-aiNet algorithm is an efficient optimization technique inspired by the immune network (aiNet), which in turn reproduces the main computational properties and functions of biological immune system. The distribution system reconfiguration problem with non-uniform variable demands is a complex problem that aims at identifying the most adequate radial topology of the network that complies with all technical constraints in every demand level while minimizing the cost of active losses along an extended operation period. This paper includes results of the application of the Opt-aiNet algorithm to distribution systems with 33, 84 and 136 buses. These results demonstrate the robustness and efficiency of the proposed method.

KEYWORDS. Distribution Systems Reconfiguration, Variable Demands, Artificial Immune Systems, Opt-aiNet.

EN – OR in Energy

1. Introdução

Nos últimos anos muitos investimentos foram aplicados nos sistemas elétricos de distribuição com o objetivo de modernizar e automatizar sua operação. Estas modernizações devem atender requisitos como a melhoria na confiabilidade, eficiência, e segurança do sistema. Neste sentido, visando atender estas exigências muitas pesquisas são realizadas, sendo uma delas a proposta de novas metodologias para resolver o problema de Reconfiguração de Sistemas de Distribuição (RSD) de energia elétrica.

O problema de RSD consiste em encontrar uma topologia radial para o sistema de distribuição através da abertura e fechamento das chaves de interconexões, de forma que seja otimizado um objetivo, que tipicamente é a minimização das perdas de potência ativa, e que sejam satisfeitas as restrições técnicas de operação do sistema elétrico, como a condição de radialidade, limites de tensão nos níveis estabelecidos pelas normas reguladoras, limites de corrente nos ramos, além de satisfazer a primeira e a segunda lei de Kirchhoff. A RSD é um procedimento realizado principalmente, com o objetivo de minimizar as perdas ativas do sistema, melhorar os níveis de tensão, manter a confiabilidade do sistema, realizar o isolamento de faltas e realizar manutenção preventiva [Guimarães et al., (2004)].

O problema de RSD é de natureza combinatória e pode ser modelado como um problema de programação não linear inteiro misto (PNLIM) [Merlin e Back (1975)]. Devido a este fato, quanto maior o tamanho do sistema elétrico, maior a dificuldade e complexidade para resolvê-lo por métodos exatos, deste modo, os métodos inteligentes de otimização como algoritmos heurísticos, meta-heurísticas, redes neurais artificiais, sistemas imunológicos artificiais, entre outros, são os mais empregados para resolver este problema, pois possuem estratégias eficientes que possibilitam reduzir o espaço de busca e encontrar a melhor solução.

Este problema já foi amplamente estudado na literatura, sendo que na maioria das abordagens tratam o problema de RSD considerando demandas invariantes nas barras consumidoras. No entanto alguns autores abordam o problema considerando demandas variáveis. O problema de RSD com demandas variáveis tem por objetivo identificar uma única topologia radial que deve operar com os diferentes níveis de demanda, de modo a minimizar o custo de perdas de energia ao longo de um período de operação.

Dentre os trabalhos mais relevantes disponíveis na literatura para resolver o problema de RSD com demandas fixas, têm-se abordagens como: algoritmos heurísticos [Merlin e Back (1975)] e [Baran e Wu (1989)], meta-heurísticas como: algoritmos genéticos [Mendonza et al. (2006)], simulated annealing [Chang e Kuo (1994)], busca tabu [Zhang et al. (2007)], colônia de formigas, [Carpaneto et al., (2008)], GRASP [Souza (2013)], redes neurais artificiais [Salazar et al., (2006)] e algoritmos imunológicos [Souza et al., (2015)], [Souza e Romero (2014a)] e [Souza e Romero (2014b)]. Também tem os trabalhos que abordam o problema de RSD com demandas variáveis, como [Bueno et al., (2004)], [Inoue et al., (2014)] e [Possagnolo (2015)].

Neste trabalho propõe-se a resolução do problema de RSD com demandas variáveis utilizando o algoritmo Opt-aiNet (Artificial Immune Network for Optimization) [de Castro e Timmis (2002)]. Na execução deste algoritmo, uma população de anticorpos é submetida a um processo de clonagem, maturação de afinidade e seleção elitista, de modo a identificar soluções para o problema de RSD. Para avaliar a afinidade dos indivíduos executa-se um algoritmo de fluxo de carga radial de varredura [Shirmohammadi et al., (1988)] para cada nível de demanda e calcula-se o custo de perdas de energia ao longo de um período de operação. Neste trabalho são apresentados resultados utilizando os sistemas elétricos de distribuição de 33, 84 e 136 barras. Os resultados confirmam a robustez e eficiência do método proposto quando comparado com a literatura.

2. O Problema de RSD com Demandas Variáveis

Como mencionado anteriormente, muitos investimentos veem sendo aplicados nos sistemas elétricos, especialmente nos sistemas de distribuição, de modo a automatizar a operação do sistema, proporcionar segurança, confiabilidade e qualidade de energia, satisfazendo as exigências impostas pelas normas do setor elétrico, com o mínimo custo possível. Neste contexto, o problema de RSD de energia elétrica é uma possível solução, pois está diretamente relacionado com o planejamento e eficiência da operação dos sistemas de distribuição de energia elétrica.

Os sistemas de distribuição de energia elétrica operam com uma topologia radial, no entanto, sua estrutura física é malhada. Isto porque, esta forma de operação proporciona condições de operação que favorecem a diminuição de dispositivos de proteção, o custo de instalação e manobras no sistema elétrico. Tal topologia proporciona maior segurança na distribuição de energia elétrica e principalmente facilita a operação e proteção do sistema elétrico [Souza et al. (2012)].

2.1. Modelo Matemático do Problema de RSD com Demandas Variáveis.

A formulação matemática genérica para o problema de RSD com demandas variáveis, considerando uma única configuração radial, sistema simétrico e equilibrado, pode ser modelado como um problema de programação não-linear inteiro misto (PNLIM), com comportamento multimodal, conforme descrito a seguir [Franco et al. (2012)]:

$$\text{Min } v = \sum_{d \in \Omega_d} \sum_{ij \in \Omega_l} c_d^l \Delta_d [g_{ij} x_{ij} (V_{i,d}^2 + V_{j,d}^2 - 2V_{i,d} V_{j,d} \cos \theta_{ij,d})] \quad (1)$$

s.a.

$$Ps_{i,d} - Pd_{i,d} - \sum_{j \in \Omega_{bi}} (x_{ij} P_{ij,d}) = 0 \quad \forall i \in \Omega_b, \forall d \in \Omega_d \quad (2)$$

$$Qs_{i,d} - Qd_{i,d} - \sum_{j \in \Omega_{bi}} (x_{ij} Q_{ij,d}) = 0 \quad \forall i \in \Omega_b, \forall d \in \Omega_d \quad (3)$$

$$\underline{V} \leq V_{i,d} \leq \bar{V} \quad \forall i \in \Omega_b, \forall d \in \Omega_d \quad (4)$$

$$(P_{ij,d}^2 + Q_{ij,d}^2) \leq \overline{S_{ij,d}^2} * x_{ij} \quad \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (5)$$

$$x_{ij} \in \{0,1\} \quad \forall ij \in \Omega_l \quad (6)$$

$$\sum_{(ij) \in \Omega_l} x_{ij} = n_b - 1 \quad (7)$$

sendo: Ω_l é o conjunto de circuitos; Ω_b é o conjunto de barras; Ω_{bi} é o conjunto de barras conectadas à barra i e o Ω_d é o conjunto de demandas; c_d^l é o custo das perdas no nível de demanda d ; Δ_d é o período de duração do nível de demanda d ; g_{ij} é a condutância do circuito ij ; $V_{i,d}$ é a magnitude de tensão na barra i , no nível de demanda d ; $\theta_{ij,d}$ é a diferença angular entre as barras i e j , no nível de demanda d ; b_{ij} é a susceptância do circuito ij ; $P_{ij,d}$ é o fluxo de potência ativa que sai da barra i para a barra j , no nível de demanda d ; $Q_{ij,d}$ é o fluxo de potência reativa que sai da barra i para a barra j , no nível de demanda d ; $Ps_{i,d}$ é a potência ativa fornecida pela subestação na barra i , no nível de demanda d ; $Qs_{i,d}$ é a potência reativa fornecida pela subestação na barra i , no nível de demanda d ; $Pd_{i,d}$ é a demanda de potência ativa na barra i , no nível de demanda d ; $Qd_{i,d}$ é a demanda de potência reativa na barra i , no nível de demanda d ; \underline{V} é a magnitude de tensão mínima; \bar{V} é a magnitude de tensão máxima; $\overline{S_{ij,d}^2}$ é o máximo valor de potência aparente no circuito ij , no nível de demanda d ; n_b é o número de barras do sistema; x_{ij} é a variável binária de decisão.

Na equação (1) tem-se a representação da função objetivo do problema, a qual é

do tipo minimização, sendo o objetivo minimizar os custos das perdas de energia elétrica no período de operação.

As restrições (2) e (3) representam a primeira e a segunda lei de Kirchhoff. Desta forma, o balanço de potências entre as barras do sistema garante o cumprimento da primeira lei de Kirchhoff e a segunda lei de Kirchhoff é garantida pelas equações (8) e (9).

$$P_{ij,d} = V_{i,d}^2 g_{ij} - V_{i,d} V_{j,d} (g_{ij} \cos \theta_{ij,d} + b_{ij} \text{sen} \theta_{ij,d}) \quad (8)$$

$$Q_{ij,d} = -V_{i,d}^2 b_{ij} - V_{i,d} V_{j,d} (g_{ij} \text{sen} \theta_{ij,d} - b_{ij} \cos \theta_{ij,d}) \quad (9)$$

A equação (4) representa a restrição dos limites de magnitude de tensão em cada barra do sistema, sendo os limites rígidos e padronizados pelas normas reguladoras dos sistemas elétricos. A restrição (5) representa o limite do fluxo de potência nos circuitos.

A restrição (6) representa a variável de decisão binária do problema, onde x_{ij} pode assumir dois estados, quando é igual a 0 (zero) significa que o circuito ij está desligado e quando é igual a 1 (um) o circuito ij está ligado.

Em (7) apresenta-se uma das condições necessárias para garantir a radialidade do sistema. Adicionalmente para garantir a radialidade é necessário garantir que todas as barras de carga do sistema sejam atendidas e isso pode ser garantido pelas restrições (2) e/ou (3), [Lavorato et al. (2012)]. Assim as restrições (2), (3) e (7) garantem que qualquer solução viável, assim como a solução ótima, seja radial.

3. Algoritmos Imunológicos Artificiais

Os algoritmos imunológicos artificiais (AIA) constituem-se de um conjunto de ferramentas inteligentes inspiradas nos mecanismos de funcionamento do sistema imunológico biológico [de Castro e Timmis (2002)]. Similarmente a outros métodos bio-inspirados e meta-heurísticas, o objetivo dos AIA é resolver problemas complexos que não podem ser resolvidos em tempo hábil por métodos tradicionais exatos.

Para a resolução de problemas de otimização, as primeiras pesquisas foram propostas no final dos anos 90, no entanto, somente a partir do ano 2000 as principais técnicas foram apresentadas. Em [de Castro e Zuben (2000)] foi proposto o algoritmo CLONALG (*Clonal Selection Algorithm*), que se inspira no princípio de seleção clonal de linfócitos B do organismo. Na sequência da evolução dos AIA, foram propostas as redes imunológicas artificiais, denominadas de aiNet (*Artificial Immune Network*). O algoritmo CLONALG e a rede aiNet são considerados base para diversos métodos propostos posteriormente, tais como: o algoritmo Opt-aiNet que é uma extensão da rede aiNet, proposto em de Castro e Timmis (2002), o algoritmo B-cell (BCA) proposto por Kelsey e Timmis (2003), o algoritmo Copt-aiNet para problemas de otimização combinatória [de Souza et al. (2004)], entre outros.

Neste trabalho será utilizado o algoritmo Opt-aiNet que é descrito na sequência. O algoritmo Opt-aiNet é uma versão da rede imunológica aiNet para resolver problemas de otimização.

3.1. Algoritmo Imunológico Artificial Opt-aiNet

O algoritmo Opt-aiNet (*Artificial Immune Network for Optimization*) foi proposto originalmente em de Castro e Timmis (2002). Sua principal diferença em relação a outros algoritmos imunológicos como CLONALG e Copt-aiNet são os processos de clonagem, mutação, tamanho populacional dinâmico, estratégias para evitar ótimos locais (supressão clonal) e seleção elitista.

O algoritmo Opt-aiNet pode ser descrito conforme apresenta o pseudocódigo a seguir [de Castro e Timmis (2002)]:

Pseudocódigo 1: Algoritmo Imunológico Artificial Opt-aiNet

```

1  Geração da População inicial: Gere uma população ( $P$ ) com  $N$  anticorpos;
2  Avaliação da afinidade: Avalie a afinidade (função objetivo) de cada anticorpo da população  $P$  e
   determine a média da afinidade populacional e armazene em OldAfinidade;
3  Enquanto (critério de parada não for satisfeito) faça
4    Enquanto (CritParada ≠ false) faça (processo iterativo interno)
5      Clonagem: Gere  $N_c$  clones para cada anticorpo da população ( $P$ ) formando subgrupos de
        anticorpos constituídos dos anticorpos originais (anticorpo pai) e os clones;
6      Hipermutação: Submeta os  $N_c$  clones de cada anticorpo pai a um processo de hipermutação;
7      Avaliação da afinidade: Avalie a afinidade (função objetivo) de cada clone maturado;
8      Seleção: Para cada subgrupo constituído de um anticorpo pai (anticorpo original) e seus
        respectivos clones maturados, selecione o anticorpo de melhor afinidade e remova os demais,
        compondo a população  $P$  com os melhores anticorpos de cada subgrupo através de um
        processo elitista;
9      Determine a média da afinidade populacional e armazene em NewAfinidade;
10     Se (OldAfinidade – NewAfinidade) < (OldAfinidade*esf) então
11       CritParada ← false;
12     Fim Se
13     OldAfinidade ← NewAfinidade;
14   Fim Enquanto
15   Supressão Clonal: Suprima os anticorpos da população  $P$  avaliando a afinidade entre eles, de modo
        que a afinidade seja maior que um limiar  $S$  (taxa de afinidade);
16   Tamanho da População: Se o tamanho da população  $P$  for menor que  $N$ , então gere anticorpos
        aleatoriamente para completar a população;
17 Fim Enquanto
  
```

Os anticorpos (propostas de soluções) podem ser codificados no formato real ou binário de acordo com o problema. Cada anticorpo gera uma quantidade total (N_c) de clones. Os clones podem sofrer mutações a uma taxa inversamente proporcional a afinidade (função objetiva). Posteriormente, um processo de seleção elitista faz a seleção dos melhores anticorpos.

A quantidade N_c de clones utilizada no processo de clonagem (linha 5) para cada anticorpo i é dada pela equação (10) [de Castro e Timmis (2002)]:

$$N_c^i = \text{round}\left(\frac{\beta N}{i}\right) \quad (10)$$

Em que β é um fator multiplicativo entre $[0,1]$, N é a quantidade total de anticorpos da população P , e $\text{round}(\cdot)$ é o operador de arredondamento para o inteiro mais próximo.

A taxa de mutação (α) de cada clone é definida pela equação (11) [de Castro e Timmis (2002)]:

$$\alpha = \exp(-\rho f^*) \quad (11)$$

sendo ρ é um parâmetro de controle de amortecimento da função exponencial, f_{\max} e f_{\min} é o valor máximo e mínimo da afinidade da população, f^* é o valor normalizado da afinidade f , que pode ser calculado conforme apresentado na equação (12) para problemas de maximização e (13) para problemas de minimização [de Castro e Timmis (2002)].

$$f^* = \frac{f}{f_{\max}} \quad (12)$$

$$f^* = \frac{f_{\min}}{f} \quad (13)$$

Cada clone sofre um processo de mutação dado por [de França et al. (2005)]:

$$m = \text{round}(\alpha * N(0,1)) \quad (14)$$

em que m é a quantidade de mutações que cada clone do anticorpo sofrerá, $\text{round}(\cdot)$ é o operador de arredondamento para o inteiro mais próximo, α é a taxa de mutação e $N(0,1)$ é uma variável randômica gaussiana de média zero e desvio padrão $\sigma = 1$.

O critério de parada do processo iterativo interno, ou simplesmente critério de

estabilização da população depende de cada problema, mas geralmente avalia-se a variação da média da afinidade populacional de uma iteração para outra durante a expansão, e quando a média da afinidade populacional não varia uma porcentagem específica (*est*) de uma iteração para outra, ocorre a estabilização da população, finalizando o processo iterativo interno.

O critério de parada comumente empregado para o algoritmo Opt-aiNet é um número definido de iterações.

4. Metodologia Proposta

Nesta seção apresenta-se a metodologia proposta para resolver o problema de RSD utilizando o algoritmo imunológico artificial Opt-aiNet.

4.1. Codificação da Proposta de Solução

Neste trabalho utilizou-se uma codificação da proposta de solução reduzida conforme apresentado em [Mendonza et al. (2006)], na qual são utilizados apenas números inteiros que indicam as posições dos ramos desligados/abertos no sistema. Esta codificação permite reduzir o espaço de busca e trabalhar somente com propostas de solução radiais, proporcionando eficiência, rapidez e robustez ao algoritmo Opt-aiNet.

Utilizando a equação (15) calcula-se o número de laços fundamentais de um sistema com todas as chaves de interconexão fechadas, e determina o tamanho do vetor de codificação da proposta de solução.

$$LF = n_l - n_b + 1 \quad (15)$$

em que: LF é a quantidade de laços fundamentais, n_l é a quantidade de circuitos e n_b é quantidade de barras.

Desta forma, após calcular quantos laços fundamentais existe no sistema, é necessário identifica-los e armazena-los. Na fase de pré-processamento, os circuitos que não formam laços no grafo do sistema e os circuitos conectados diretamente a subestação inicializam o processo iterativo do algoritmo Opt-aiNet conectados. Na Figura 1 ilustra-se o sistema teste de 14 barras e o conjunto de laços fundamentais, que são apresentados em (16), (17) e (18).

Na Figura 1, o circuito C_9 destacado em vermelho não faz parte de nenhum laço no grafo do sistema e, portanto, faz parte de qualquer topologia radial. Os circuitos C_1 , C_5 e C_{10} (em vermelho) são conectados a subestação, portanto, iniciam o processo ligados.

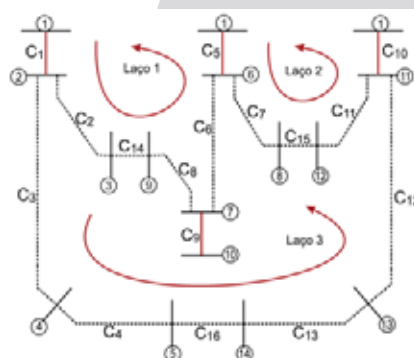


Figura 1 – Laços fundamentais para o sistema de 14 barras

O sistema de 14 barras apresentado na Figura 1 possui três laços fundamentais, desta forma, o vetor de codificação da proposta de solução será um vetor com três posições, e conseqüentemente, com três circuitos desconectados (abertos) na topologia do sistema. A partir dos laços fundamentais apresentados em (16)-(18) escolhe-se um circuito de cada laço para ficar desligado no sistema, gerando uma proposta de solução.

$$L_1 = [C_2, C_{14}, C_8, C_6] \quad (16)$$

$$L_2 = [C_7, C_{15}, C_{11}] \quad (17)$$

$$L_3 = [C_2, C_{14}, C_8, C_6, C_7, C_{15}, C_{11}, C_{12}, C_{13}, C_{16}, C_4, C_3] \quad (18)$$

Ressalta-se que ao escolher os circuitos nos laços fundamentais realizam-se verificações para que a topologia final seja radial. Por exemplo, escolhendo os ramos C_8 , C_{11} e C_4 obtém-se o vetor de codificação de uma proposta de solução radial, conforme apresentado em (19).

$$[C_8 \ C_{11} \ C_4] \quad (19)$$

4.2. Heurística para Gerar a População Inicial

Para gerar a população inicial do algoritmo Opt-aiNet foram utilizados conceitos apresentados no tópico anterior, como a codificação da proposta de solução e os laços fundamentais do sistema.

A população inicial é constituída pelos anticorpos (propostas de solução) que são gerados através de uma escolha aleatória. Para codificar um anticorpo utiliza-se a codificação do problema, de modo que para cada laço fundamental do sistema, um circuito é escolhido para ficar desconectado. Cada posição do vetor solução representa um laço fundamental, e o valor codificado na posição se refere ao circuito desconectado no laço fundamental. A estratégia para gerar a população inicial (P) é descrita nos passos a seguir [Mendonza et al. (2006)]:

Pseudocódigo 2: Heurística para gerar a população inicial

1	Faça a leitura dos laços fundamentais armazenados (L) e obtenha LF (quantidade de laços);
2	Defina o tamanho da população (N);
3	Para $i=1$ até N faça
4	Para $j=1$ até LF faça
5	Escolha aleatoriamente um circuito pertencente ao laço fundamental j (L_j) para ser desconectado, desde que este circuito não seja proibido para escolha, e conecte os demais circuitos do laço L_j . Todos os circuitos (o circuito escolhido e os demais que foram conectados) passam a ser circuitos proibidos para escolha em outros laços fundamentais;
6	Fim Para
7	Fim Para

No passo 5 do pseudocódigo existe uma estratégia que analisa os circuitos escolhidos em cada laço fundamental, de modo que ao escolher um circuito para ficar desconectado no sistema, automaticamente este circuito se torna proibido para ser escolhido novamente em outro laço fundamental. Também nesta estratégia, os circuitos que pertencem ao laço fundamental com circuito já desconectado, são conectados, isto é, ligados, também, sendo proibidos de serem escolhidos em outros laços fundamentais. Esta estratégia permite a geração de propostas de soluções topologicamente factíveis (radiais).

4.3. Avaliação da Afinidade

O operador de avaliação de afinidade é responsável por calcular o valor de afinidade (custo de perdas de energia) de cada indivíduo da população (P). Desta forma, para realizar esta tarefa executa-se um problema de fluxo de carga de varredura [Shirmohammadi et al., (1988)], identificando as perdas de potência ativas para cada nível de demanda do sistema. Após identificar as perdas ativas para todas as demandas do sistema, calcula-se o custo de perdas de energia (US\$) para o período de operação, utilizando a equação apresentada em (20).

$$f = \sum_{i=1}^T [K_i * T_i * P_i] \quad (20)$$

em que: T é a quantidade de demandas de energia, K_i é o custo de perda de energia na

demanda i , T_i é o tempo de operação na demanda i , e P_i é o valor de perdas ativas para a demanda i .

4.4. Processo de Clonagem

No processo de clonagem geram-se Nc clones para cada anticorpo da população (P) formando subgrupos de anticorpos constituídos dos anticorpos originais (anticorpo pai) e os clones gerados. Para calcular a quantidade Nc de clones que cada anticorpo irá possuir, utiliza-se a equação (10).

4.5. Processo de Hipermutação

Após gerar os Nc clones para cada anticorpo original realiza-se o processo de hipermutação, gerando clones maturados. Inicialmente é necessário calcular a quantidade de mutações que um anticorpo i sofrerá no processo iterativo do algoritmo Opt-aiNet, assim utiliza-se a equação (14). A taxa de mutação (α) é definida em (11) e a afinidade normalizada (f^*) é definida em (13). Na sequência realiza-se uma mutação conforme o pseudocódigo a seguir:

Pseudocódigo 3: Operador de Hipermutação

1	Faça a leitura dos Nc clones gerados para a população P ;
2	Para $i=1$ até Nc faça
3	Calcule a quantidade de mutações (m) para o anticorpo i ;
4	Para $j=1$ até m faça
5	Escolha uma posição l aleatoriamente do anticorpo i . Esta posição l representa um laço fundamental ($l \in LF$);
6	Escolha um circuito do laço fundamental (L_l), desde que este circuito não esteja desconectado em outra posição do anticorpo i . Avalie se ao realizar a troca o anticorpo será radial. Se for radial, troque o circuito escolhido pelo circuito da posição l . Caso contrário, escolha outro circuito;
7	Fim Para
8	Armazene o anticorpo i maturado;
9	Fim Para
10	Retorne Clones maturados;

Na Figura 2 ilustra-se um exemplo do processo de hipermutação descrito no pseudocódigo 3. Neste exemplo foi realizada a hipermutação com o anticorpo apresentado em (19). Os laços fundamentais do sistema de 14 barras são apresentados em Laço 1, Laço 2 e Laço 3 conforme a Figura 2.




Figura 2 – Exemplo do processo de hipermutação para o sistema de 14 barras.

Neste processo de hipermutação inicialmente foi escolhida a posição 2 do anticorpo, ou seja, o Laço 2 foi escolhido. Na sequência escolhe-se aleatoriamente um circuito pertencente ao Laço 2, de forma que a escolha leve a uma codificação radial e diferente do anticorpo original. Por fim os circuitos são trocados (circuito 11 é trocado pelo circuito 15), gerando o anticorpo maturado.

4.6. Processo de Seleção Elitista

Durante o processo iterativo interno do algoritmo Opt-aiNet ocorre um processo

de seleção elitista, de modo que sempre o anticorpo de melhor afinidade de cada subconjunto de anticorpos (anticorpo pai e clones maturados) permaneça na população P após o processo de clonagem e hipermutação. Este processo garante que em toda iteração do algoritmo os melhores anticorpos (elites), nunca sejam substituídos por anticorpos de pior afinidade.

4.7. Critério de Parada do Processo Iterativo Interno

A parada do processo iterativo interno ocorre quando a população se estabiliza, ou seja, quando a média da afinidade populacional não tem uma grande variação de uma iteração para outra durante o processo iterativo interno. Quando a média da afinidade populacional não varia em uma porcentagem específica (esf) de uma iteração para outra a população é considerada estável, e assim o processo é finalizado.

4.8. Processo de Supressão Clonal

No processo de supressão clonal avalia-se a população P , comparando as topologias dos anticorpos aos pares, e avaliando a semelhança entre eles, utilizando a métrica de avaliação de similaridade topológica. Caso a semelhança entre o par de anticorpos seja maior que um limiar S (taxa de afinidade) descarta-se um dos anticorpos do par, realizando o processo de supressão clonal. Neste processo os anticorpos que forem semelhantes são eliminados, de modo a proporcionar maior diversidade populacional.

4.9. Processo de Controle de Tamanho Populacional

Após o processo de supressão clonal, deve-se verificar se o tamanho da população (P) é menor que N , caso seja, então são gerados novos anticorpos aleatoriamente utilizando a heurística apresentada em 4.2 para completar a população (P).

4.10. Critério de Parada

Para o algoritmo Opt-aiNet o critério de parada utilizado foi um número definido de gerações (ger).

5. Resultados

Nesta seção apresentam-se os resultados obtidos com a aplicação do algoritmo Opt-aiNet nos sistemas testes de 33, 84 e 136 barras. O algoritmo Opt-aiNet foi escrito na linguagem C++ Builder® [Borland (2006)]. Foram utilizados os sistemas testes de 33, 84 e 136 barras. Os dados de barras e circuitos dos sistemas testes estão disponíveis em [Baran e Wu (1989)], [Chiou et al. (2005)] e [Zhang et al. (2007)].

5.1. Demandas Típicas Utilizadas

Para os resultados apresentados neste trabalho foram considerados 24 níveis de demanda, sendo uma demanda para cada hora do dia, em um período de operação de 24 horas. As barras consumidoras dos sistemas foram definidas em três tipos de cargas típicas, conforme apresentado na Tabela 1, sendo: residencial, comercial e industrial.

Para obter a demanda de cada barra em cada período de análise, multiplica-se o fator de carga dado por cada tipo de consumidor pelos valores de potência ativa e reativa de cada barra do sistema elétrico. A escolha do tipo de consumidor de cada barra foi realizada aleatoriamente, sendo que o tipo residencial foi definido em 60% das barras, comercial em 25% e industrial em 15%. Adicionalmente na Tabela 1, apresenta-se os valores dos custos

das perdas, em um período de 24 horas. Estes valores foram utilizados como custos das perdas para cada demanda ao longo do período de operação. O tipo de consumidores definidos para cada barra do sistema pode ser encontrado em [Possagnolo (2015)].

Tabela 1 – Demandas Típicas.

Nível de Demanda	Tipo de Consumidor			Custo (US\$/kWh)
	Residencial	Comercial	Industrial	
1	0,3600	0,2838	0,0625	0,0650
2	0,2600	0,2973	0,1000	0,0650
3	0,2400	0,2838	0,0750	0,0650
4	0,2200	0,3108	0,1188	0,0650
5	0,2400	0,2938	0,1000	0,0650
6	0,4200	0,3378	0,0875	0,0650
7	0,5400	0,4054	0,1375	0,1100
8	0,5600	0,5270	0,3875	0,1100
9	0,5400	0,7297	0,7438	0,1100
10	0,5800	0,8311	0,7625	0,1100
11	0,4300	1,0000	0,9000	0,1100
12	0,4800	0,9595	1,0000	0,1100
13	0,5800	0,9324	0,6188	0,1100
14	0,5200	0,9595	0,6875	0,1100
15	0,4100	0,9730	0,7875	0,1300
16	0,4600	0,9595	0,7625	0,1300
17	0,4200	0,9730	0,8125	0,1300
18	0,4900	0,9189	0,8750	0,1300
19	0,7900	0,7838	0,6188	0,1500
20	0,9840	0,7162	0,3563	0,1500
21	0,9700	0,6622	0,2375	0,1500
22	1,0000	0,5811	0,1250	0,0650
23	0,5400	0,5000	0,1188	0,0650
24	0,4200	0,3229	0,0832	0,0650

5.1. Parâmetros do Algoritmo Opt-aiNet

Os resultados para os sistemas de 33, 84 e 136 barras foram obtidos utilizando os parâmetros apresentados na Tabela 2. Todos os parâmetros foram obtidos de forma empírica, através de testes.

Tabela 2 - Parâmetros.

Parâmetros	N	β	ger	ρ	S	est	ϵ
	40	0,5	30	4	80%	$2 \cdot ger$	10^{-6}

sendo: N a quantidade de anticorpos na população, β o fator de clonagem, ger o número de gerações, ρ a taxa de amortecimento da função exponencial, S é o limiar de afinidade, est o critério de estabilização e ϵ a tolerância do fluxo de carga. Os parâmetros adotados para todos os sistemas testes são os mesmos, proporcionando robustez ao método proposto.

5.1. Sistemas de 33, 84 e 136 Barras

Na Tabela 3 apresentam-se os resultados para os sistemas de 33, 84 e 136 barras, que foram obtidos através de um teste de referência cruzada em 30 execuções.

Para os sistemas testes de 33, 84 e 136 barras o algoritmo Opt-aiNet encontrou as melhores soluções (topologia e perdas ativas) disponíveis na literatura, considerando a estratégia de demandas variável adotada, conforme apresentado em [Possagnolo (2015)].

Para o sistema de 33 barras, o algoritmo Opt-aiNet encontrou uma solução com custo diário das perdas de energia de 128,81 US\$, que representa uma melhoria de 31,43% em relação a topologia inicial. Para o sistema de 84 barras, o custo diário das perdas de energia foi de 410,53 US\$, que representa uma melhoria de 10,05% em relação a topologia inicial. Por fim, para o sistema de 136 barras, o custo de diário de perdas encontrado foi de

256,89 US\$, e representa uma melhoria de 10,95% em relação a topologia inicial.

Tabela 3 – Resultados para os sistemas 33, 84 e 136 barras.

Sistema	Topologia	Custo Diário das Perdas (US\$)	Circuitos abertos
33	Inicial	187,86	33-34-35-36-37
	1 nível de demanda	134,30	7-9-14-32-37
	Final	128,81	7-9-14-28-32
	[Possagnolo (2015)]	128,81	7-9-14-28-32
84	Inicial	456,41	84-85-86-87-88-89-90-91-92-93-94-95-96
	1 nível de demanda	417,29	7-13-34-39-42-55-62-72-83-86-89-90-92
	Final	410,53	7-34-39-63-72-83-84-86-88-89-90-92-95
	[Possagnolo (2015)]	410,53	7-34-39-63-72-83-84-86-88-89-90-92-95
136	Inicial	288,50	136-137-138-139-140-141-142-143-144-145-146-147-148-149-150-151-152-153-154-155-156
	1 nível de demanda	272,97	7-35-51-90-96-106-118-126-135-137-138-141-142-144-145-146-147-148-150-151-155
	Final	256,89	7-38-51-54-84-90-96-106-118-126-135-137-138-141-144-145-147-148-150-151-155
	[Possagnolo (2015)]	256,89	7-38-51-54-84-90-96-106-118-126-135-137-138-141-144-145-147-148-150-151-155

Para encontrar a solução dos sistemas de 33, 84 e 136 barras foram executadas 30 gerações do algoritmo Opt-aiNet para cada sistema, e o tempo computacional médio foi de 0,321; 4,264 e 21,952 segundos respectivamente.

7. Conclusão

Neste trabalho, foi apresentada uma nova abordagem para resolver o problema de RSD com demandas variáveis utilizando o algoritmo imunológico artificial Opt-aiNet, tendo como objetivo a minimização dos custos de perdas de energia do sistema.

O algoritmo Opt-aiNet é uma técnica de otimização inspirada no funcionamento do sistema imunológico biológico, em essencial, no princípio da rede imunológica (aiNet). O algoritmo apresentou estabilidade e sempre encontra soluções factíveis para o problema de RSD com demandas variáveis.

Os resultados encontrados para os três sistemas testes foram comparados com os resultados existentes na literatura, de forma a comprovar a eficiência da metodologia proposta. Por fim, conclui-se que o algoritmo Opt-aiNet proposto neste trabalho apresentou um ótimo desempenho, com eficiência, baixo tempo de processamento e robustez.

Agradecimentos

Agradecemos a CAPES-PDSE (Proc. Nº BEX 3660/14-1) e ao CNPq pelo apoio financeiro de pesquisa.

Referências

- Baran, M. E.; Wu, F. F.** (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power Delivery*, New York, v. 4, n. 2, pp. 1401-1407.
- Borland** (2011). 6.0 Version, C++ Builder.
- Bueno, E. A.; Lyra, C.; Cavellucci, C.** (2004). Distribution network reconfiguration for loss reduction with variable demands. *IEEE Latin America Transmission and Distribution Conference*, pp. 384-389.
- Carpaneto, E.; Chicco, G.** (2008). Distribution system minimum loss reconfiguration in the hypercube ant colony optimization framework. *Electric Power Systems Research*, Lausanne, v. 78, pp. 2037-2045.
- Chang, H. C.; Kuo, C. C.** (1994). Network reconfiguration in distribution systems using simulated annealing. *Electric Power Systems Research*, Lausanne, v. 29, n. 3, pp. 227-238.
- Chiou, J. P.; Chang, C. F.; Su, C. T.** (2005). Variable scaling hybrid differential evolution for solving

- network reconfiguration of distribution systems. *IEEE Transactions on Power Systems*, New York, v. 20, n. 2, pp. 668-674.
- de Castro, L. N. e Timmis, J.** (2002) An artificial immune network for multimodal function optimization, *Proc. Of IEEE World Congress on Evolutionary Computation*, 2002.
- de Castro, L. N. e Zuben, F. J. V.** (2000) The clonal selection algorithm with engineering applications, *Workshop on Artificial Immune Systems and Their Applications*, pp. 36-37.
- de Franca, F. O., Von Zuben, F. J., de Castro, L. N.** (2005). An Artificial Immune Network for Multimodal Function Optimization on Dynamic Environments. In: *Proc. GECCO*, Washington, DC, USA, pp. 289-296.
- de Souza, J. S., Zuben, F. J. V., de Castro Silva, L. N., e Sousa, J. S.** (2004). An immune evolutionary algorithm for multiple rearrangements of gene expression data. *Genetic Programming and Evolvable Machines*, v. 5, pp. 157-179, Hingham, MA, USA. Kluwer Academic Publishers.
- Franco, J.; Lavorato, M.; Rider, M. J.; Romero, R.** (2012). An efficient implementation of tabu search in feeder reconfiguration of distribution systems. *IEEE PES General Meeting*, pp. 1-8.
- Guimarães, M. A. N.; Lorenzetti, J. F. C.; Castro, C. A.** (2004). Reconfiguration of Distribution System for Voltage Stability margin Enhancement Using Tabu Search. *Proc. Powercon*, pp. 1556-1561.
- Inoue, T.; Takano, K.; Watanabe, T.; Kawahara, J.** (2014). Distribution loss minimization with guaranteed error bound. *IEEE Transaction on Smart Grid*, v. 5, n. 1, pp. 102-111.
- Kelsey, J. e Timmis, J.** (2003) Immune inspired somatic contiguous hypermutation for function optimisation, *GECCO*, pp. 207-218.
- Lavorato, M.; Franco, J. F.; Rider, M. J.; Romero, R.** (2012). Imposing Radiality Constraints in Distribution System Optimization Problems, *IEEE Transaction on Power Systems*, New York, v. 27, n. 1, pp. 172-180.
- Mendoza, J.; Lopez, R.; Morales, D.; Lopez, E.; Dessante, P.; Moraga, R.** (2006). Minimal loss reconfiguration using genetic algorithms with restricted population and addressed operators: Real applications”, *IEEE Transactions on Power Systems*, Vol. 21, No. 2, pp. 948-954.
- Merlin, A.; Back, H.** (1975). Search for a minimal-loss operating spinning tree configuration in an urban power distribution system. *Power System Computation Conference*, pp. 1-18.
- Possagnolo, L. H. F. M.** “Reconfiguração de Sistemas de distribuição operando em vários níveis de demanda através de uma meta-heurística de busca em vizinhança variável,” *Dissertação*, Departamento de Eng. Elétrica, Univ. Estadual Paulista – UNESP, campus Ilha Solteira, 2015.
- Salazar, H.; Gallego, R.; Romero, R.** (2006). Artificial neural networks and clustering techniques applied in the reconfiguration of distribution systems. *IEEE Transactions on Power Delivery*, New York, v. 21, n. 3, pp. 1735-1742.
- Shirmohammadi, D.; Hong, H.W.; Semlyen, A.; Luo, G. X.** (1988). A Compensation Based Power Flow Method for Weakly Meshed Distribution and Transmission Networks, *IEEE Transactions on Power Systems*, vol. 3, no. 2, pp. 753-762.
- Souza, S. S. F.; Romero, R.; Franco, J. F.** (2015). Artificial immune networks Copt-aiNet and Opt-aiNet applied to the reconfiguration problem of radial electrical distribution systems. *Electric Power Systems Research*, Lausanne, v. 119, pp. 304-312.
- Souza, S. S. F.; Romero, R.** (2014a) Reconfiguração de Sistemas de Distribuição Usando um Algoritmo Imunológico Artificial CLONALG. *Congresso Brasileiro de Automática*, pp. 2137-2144.
- Souza, S. S. F.; Romero, R.** (2014b) Reconfiguração de Sistemas de Distribuição de Energia Elétrica Utilizando o Algoritmo Imunológico Artificial Copt-aiNet. *SOBRAPO*, pp. 1-12.
- Souza, S. S. F.** “Algoritmo GRASP especializado aplicado ao problema de reconfiguração de alimentadores em sistemas de distribuição radial,” *Dissertação*, Departamento de Eng. Elétrica, Univ. Estadual Paulista – UNESP, campus Ilha Solteira, 2013.
- Souza, S. S. F.; Lavorato, M.; Romero, R.** (2012) GRASP especializado aplicado ao problema de reconfiguração de sistemas de distribuição, *IEEE PES T&D Latin América*, pp. 1-6.
- Zhang, D.; Fu, Z.; Zhang, L.** (2007). An improved TS algorithm for loss-minimum reconfiguration in large-scale distribution systems. *Electric Power Systems Research*, Lausanne, v. 77, n. 5-6, pp. 685-694.