

Meta-heurística de Fogos de Artifício de Busca Dinâmica com Mutaç o de Covari ncia Aplicada ao Problema de Fluxo de Pot ncia  timo

Marco Meneses, Leonardo H. Macedo, Rub n Romero

Departamento de Engenharia El trica

UNESP – Universidade Estadual Paulista

Ilha Solteira, Brasil

mameneseso@gmail.com, leohfmp@gmail.com, ruben@dee.feis.unesp.br

Resumo—Neste trabalho apresenta-se uma vers o especializada do algoritmo de fogos de artif cio de busca din mica com muta o de covari ncia (AFABDMC) para resolver o problema de fluxo de pot ncia  timo em sistemas de transmiss o. No algoritmo proposto considera-se como vari veis cont nuas de controle a magnitude da tens o e a gera o de pot ncia ativa nas barras de gera o e como vari veis de controle discretas o estado de opera o dos *shunts* e a posi o do comutador de *taps* em transformadores. Assim, o modelo para o problema   de programa o n o-linear inteira mista. A estrat gia de resolu o adotada consiste em definir, em cada itera o, as vari veis discretas utilizando-se a meta-heur stica AFABDMC e utiliz las no modelo de programa o n o-linear (PNL) que fornece os valores das vari veis de controle cont nuas junto com o estado de opera o do sistema. A meta-heur stica foi escrita em linguagem MATLAB e o modelo do problema em AMPL. Os subproblemas de PNL foram resolvidos utilizando-se o solver KNITRO, sendo que a interface entre o MATLAB e o AMPL foi feita utilizando-se o AMPL API. Foram realizados testes com os sistemas IEEE de 57 e 118 barras e os resultados indicam que a metodologia proposta   capaz de encontrar solu o es de excelente qualidade para o problema.

Palavras-chave—Algoritmo de fogos de artif cio, busca din mica, fluxo de pot ncia  timo ativo-reativo, meta-heur stica, muta o de covari ncia.

I. INTRODU O

Desde sua concep o em 1962 [1], o problema do fluxo de pot ncia  timo (FPO) tem sido objeto de muitas investiga o es no campo da pesquisa operacional e   de interesse para as companhias geradoras e transmissoras de energia el trica para otimizar a opera o dos seus sistemas de pot ncia. No problema de FPO, otimiza-se alguma fun o objetivo de interesse ajustando as vari veis de controle do sistema de pot ncia, de forma a satisfazer restri o es de igualdade e desigualdade de acordo as propriedades do sistema. Por se tratar de um problema de programa o n o-linear inteira mista (PNLIM), v rias metodologias de resolu o foram desenvolvidas. Em [2] e [3]   apresentada uma revis o completa sobre os principais trabalhos no tema, sendo que [2] enfoca nas t cnicas cl ssicas e [3] em meta-heur sticas.

O algoritmo de fogos de artif cio (AFA), inspirado pela explos o de fogos de artif cio, foi introduzido em 2010 pelo

pesquisador Ying Tan [4]. A ideia b sica deste algoritmo consiste em que quando um fogo de artif cio explode, uma chuva de fa scas aparece em torno dele, ou no caso de otimiza o num rica, um conjunto de solu o es novas s o geradas. O algoritmo de fogos de artif cio de busca din mica com muta o de covari ncia (AFABDMC), usado neste trabalho, foi desenvolvido em 2015 pelo autor original do algoritmo e apresenta melhorias nos operadores [5].

No presente trabalho, a fun o objetivo   a minimiza o do custo de gera o de pot ncia ativa. As vari veis de controle a serem usadas podem ser [6]:

- Gera o de pot ncia ativa das unidades geradoras P_i^g ;
- Tens o nas unidades geradoras V_i^g ;
- Posi o dos *taps* dos transformadores t_{ij} ;
- Status dos reatores e capacitores chaveados ω_i .

De forma geral, a maior parte das t cnicas de otimiza o cl ssica utilizam algoritmos de otimiza o baseados em an lises de sensibilidade e em c lculo de gradientes, usando para isso fun o es objetivos linearizadas e trabalhando em torno a certo ponto de opera o.

O problema do FPO   um problema de otimiza o de grande porte, altamente n o-linear, multi-modal e restrito, que usa fun o es objetivos n o-convexas, n o-suaves e n o diferenci veis, nas quais podem existir mais de um  timo local e n o existe um crit rio para se saber se um  timo local   a solu o global. Por esse motivo n o   adequado usar t cnicas de otimiza o local para solucionar este problema, nem usar suposi o es como fun o es objetivo convexas, anal ticas e diferenci veis para simplificar este problema [7], [8]. Assim, o uso de t cnicas meta-heur sticas permite lidar com o problema do FPO sem fazer uso dessas lineariza o es e permite obter resultados de melhor qualidade do que com os outros m todos.

Neste trabalho, o AFABDMC   utilizado para definir os valores das vari veis inteiras do problema, enquanto que as vari veis de controle cont nuas s o otimizadas utilizando-se um modelo de programa o n o-linear (PNL), que tamb m fornece o estado de opera o do sistema e o valor da fun o objetivo. A meta-heur stica foi escrita em MATLAB e o modelo do problema em AMPL. Os subproblemas de PNL foram resolvidos com o *solver* KNITRO, com interface entre o

MATLAB e o AMPL feita pelo AMPL API. Foram realizados testes com os sistemas IEEE de 57 e 118 barras.

II. MODELO DE OTIMIZAÇÃO

O modelo do problema de FPO é mostrado em (1)–(18):

$$\min v = \sum_{i \in \Omega_g} \left[c_i^g (P_i^g)^2 + c_i^l P_i^g + c_i^o \right] + \rho \sum_{i \in \Omega_b^l} (g_i^P + g_i^Q) \quad (1)$$

Sujeito a:

$$P_i^g - P_i^d - \sum_{ji \in \Omega_l} P_{ji}^{para} - \sum_{ij \in \Omega_l} P_{ij}^{de} - V_i^2 G_i^{sh} + g_i^P = 0 \quad \forall i \in \Omega_b \quad (2)$$

$$Q_i^g - Q_i^d - \sum_{ji \in \Omega_l} Q_{ji}^{para} - \sum_{ij \in \Omega_l} Q_{ij}^{de} + V_i^2 B_i^{sh} \omega_i + g_i^Q = 0 \quad \forall i \in \Omega_b \quad (3)$$

$$P_{ij}^{de} = G_{ij} \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right)^2 V_i^2 - \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right) V_i V_j [G_{ij} \cos(\theta_i - \theta_j + \phi_{ij}) + B_{ij} \text{sen}(\theta_i - \theta_j + \phi_{ij})] \quad \forall ij \in \Omega_l \quad (4)$$

$$P_{ij}^{para} = G_{ij} V_j^2 - \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right) V_i V_j [G_{ij} \cos(\theta_i - \theta_j + \phi_{ij}) - B_{ij} \text{sen}(\theta_i - \theta_j + \phi_{ij})] \quad \forall ij \in \Omega_l \quad (5)$$

$$Q_{ij}^{de} = - (B_{ij} + B_{ij}^{shl}) \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right)^2 V_i^2 + \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right) V_i V_j [B_{ij} \cos(\theta_i - \theta_j + \phi_{ij}) - G_{ij} \text{sen}(\theta_i - \theta_j + \phi_{ij})] \quad \forall ij \in \Omega_l \quad (6)$$

$$Q_{ij}^{para} = - (B_{ij} + B_{ij}^{shl}) V_j^2 + \left(1 + r_{ij}^{\%} \frac{t_{ij}}{\bar{t}_{ij}} \right) V_i V_j [B_{ij} \cos(\theta_i - \theta_j + \phi_{ij}) + G_{ij} \text{sen}(\theta_i - \theta_j + \phi_{ij})] \quad \forall ij \in \Omega_l \quad (7)$$

$$\underline{V} \leq V_i \leq \bar{V} \quad \forall i \in \Omega_b \quad (8)$$

$$\underline{P}_i^g \leq P_i^g \leq \bar{P}_i^g \quad \forall i \in \Omega_g \quad (9)$$

$$\underline{Q}_i^g \leq Q_i^g \leq \bar{Q}_i^g \quad \forall i \in \Omega_g \quad (10)$$

$$(P_{ij}^{de})^2 + (Q_{ij}^{de})^2 \leq \bar{S}_{ij}^2 \quad \forall ij \in \Omega_l \quad (11)$$

$$(P_{ij}^{para})^2 + (Q_{ij}^{para})^2 \leq \bar{S}_{ij}^2 \quad \forall ij \in \Omega_l \quad (12)$$

$$g_i^P, g_i^Q \geq 0 \quad \forall i \in \Omega_b^l \quad (13)$$

$$g_i^P, g_i^Q = 0 \quad \forall i \in \Omega_g \quad (14)$$

$$-\bar{t}_{ij} \leq t_{ij} \leq \bar{t}_{ij} \quad \forall ij \in \Omega_l \quad (15)$$

$$\theta_i = 0 \quad i = \text{slack} \quad (16)$$

$$\omega_i \in \{0, 1\} \quad \forall i \in \Omega_b \quad (17)$$

$$t_{ij} \text{ inteiro} \quad \forall ij \in \Omega_l \quad (18)$$

No modelo apresentado nas equações (1)–(18), v representa a função de custo de geração, sendo P_i^g a potência ativa gerada na barra i e os valores c_i os coeficientes de custo dos geradores, penalizada pelo somatório dos cortes de carga ativa e reativa, g_i^P e g_i^Q , sendo ρ o parâmetro de penalização. P_i^d e Q_i^d são as potências ativa e reativa demandadas na barra i , Q_i^g é a potência reativa gerada na barra i , V_i é a magnitude de tensão na barra i , G_i^{sh} e B_i^{sh} são a condutância e susceptância *shunt* conectadas à barra i , ω_i é a variável binária de chaveamento do *shunt* conectado à barra i , G_{ij} e B_{ij} são os valores de condutância e susceptância do ramo ij , B_{ij}^{shl} é a susceptância *shunt* da linha no ramo ij , $r_{ij}^{\%}$ é o tamanho de passo de regulação para o *tap* do transformador no ramo ij , t_{ij} a posição do *tap* do transformador no ramo ij , $\bar{t}_{ij}$ o número de *taps* do transformador no ramo ij , θ_i o ângulo da tensão na barra i , ϕ_{ij} o valor do ângulo de defasagem introduzido pelo transformador defasador no ramo ij , $\underline{V}$ e $\bar{V}$ os limites inferior e superior da tensão nas barras, $\underline{P}_i^g$ e $\bar{P}_i^g$ os limites inferior e superior de geração de potência ativa na barra i , $\underline{Q}_i^g$ e $\bar{Q}_i^g$ os limites inferior e superior de geração de potência reativa na barra i , $\bar{S}_{ij}$ o limite fluxo de potência aparente da linha no ramo ij , Ω_b é o conjunto de barras, Ω_b^l é o conjunto de barras de carga, Ω_g é o conjunto de barras geradoras e Ω_l é o conjunto de ramos.

As equações (2) e (3) representam os balanços de potência ativa e reativa no sistema (primeira lei de Kirchhoff), (4)–(7) representam os cálculos dos fluxos de potência ativa e reativa nos ramos, (8) é o limite de tensão nas barras, (9) e (10) são as restrições de capacidade de geração de potência ativa e reativa, respectivamente, (11) e (12) são os limites de capacidade das linhas de transmissão, (13) e (14) definem os cortes de carga nas barras, como não-negativos nas barras de carga e como zero nas barras de geração, (15) representa o limite de posições dos *taps* dos transformadores, (16) impõe a referência angular no sistema. Finalmente, (17) e (18) representam a natureza discreta das variáveis referentes à operação dos *shunts* e dos *taps* dos transformadores.

III. ALGORITMO DE FOGOS DE ARTIFÍCIO

O Algoritmo de Fogos de Artifício [4] foi proposto como um algoritmo de inteligência de enxame para a otimização global de funções complexas e está inspirado na explosão de fogos de artifício no céu. A ideia fundamental é que quando um dos fogos de artifício explode, aparecem faíscas de explosão ou novas soluções em torno da sua localização, ou seja, com deslocamentos aleatórios [9]. Ele utiliza uma população base de fogos de artifício de tamanho N_F de dimensão D , cada um dos quais explode com amplitude de explosão e número de faíscas geradas de forma proporcional à avaliação da função objetivo.

A. Geração das faíscas de explosão

As faíscas de explosão representam novas soluções e são geradas pela explosão dos fogos de artifício da população base. Para gerá-las é preciso calcular os parâmetros de número de faíscas de explosão geradas por fogo de artifício S_i e a

amplitude de explosão do fogo de artifício A_i . Por definição, a meta-heurística é apresentada para um processo de minimização da função objetivo. A ideia do cálculo do número de faíscas de explosão é que esta favoreça ao melhor fogo de artifício, concedendo-lhe um maior número de faíscas de explosão do que aos piores.

$$S_i = N_E \cdot \frac{Y_{max} - f(x_i) + \epsilon}{\sum_{i=1}^{N_F} (Y_{max} - f(x_i)) + \epsilon} \quad (19)$$

Em (19), S_i é o número de faíscas de explosão geradas pelo fogo de artifício i , N_E é o número total de faíscas de explosão geradas por iteração, mas como será indicado na equação (20), essa constante pode mudar pela normalização do número de faíscas de explosão, Y_{max} é o pior valor da função objetivo da população atual de fogos de artifício, em um problema de minimização, esse valor corresponde ao maior valor da função objetivo dos fogos de artifício, $f(x_i)$ é a avaliação da função objetivo do indivíduo x_i , ϵ é uma constante de valor muito baixo, para impedir o denominador se tornar zero e N_F é o número de fogos de artifício.

Para evitar o efeito de dominância das melhores soluções e evitar que as piores soluções não gerem faíscas de explosão, é introduzida uma regra para limitar os valores máximo e mínimo de número de faíscas de explosão geradas por fogo de artifício (20):

$$S_i = \begin{cases} \text{arredondar}(a \cdot N_E) & \text{se } S_i < a \cdot N_E \\ \text{arredondar}(b \cdot N_E) & \text{se } S_i > b \cdot N_E \\ \text{arredondar}(\hat{S}_i) & \text{em outro caso} \end{cases} \quad (20)$$

Em (20), a é uma constante para regular o mínimo número de faíscas geradas por fogo de artifício e b é uma constante para regular o máximo.

A ideia do cálculo da amplitude de explosão é que quanto melhor seja uma solução, menor é a amplitude de explosão para favorecer a busca local, e no caso das piores soluções, sua amplitude de explosão é maior para favorecer a busca global de soluções.

$$A_i = \hat{A} \cdot \frac{f(x_i) - Y_{min} + \epsilon}{\sum_{i=1}^{N_F} (f(x_i) - Y_{min}) + \epsilon} \quad (21)$$

Em (21), A_i é a amplitude de explosão do fogo de artifício i , $\hat{A}$ é a amplitude máxima de explosão dos fogos de artifício, Y_{min} é o melhor valor da função objetivo da população atual de fogos de artifício, em um problema de minimização, esse valor corresponde ao menor valor da função objetivo dos fogos de artifício, $f(x_i)$ é a avaliação da função objetivo do indivíduo x_i , ϵ é uma constante de valor muito baixo para impedir o denominador se tornar zero e N_F é o número de fogos de artifício.

Uma vez calculados estes parâmetros, as faíscas de explosão são criadas copiando o fogo de artifício base deslocando k dimensões aleatórias, multiplicando-as por um número aleatório com distribuição uniforme com valores entre -1 e 1 ($U(-1, 1)$) e pela amplitude de explosão correspondente A_i .

Após a explosão, a estratégia de mapeamento assegura que todas as faíscas geradas fiquem dentro do espaço de busca

factível. Esta é aplicada quando for detectado que alguma dimensão de uma das faíscas saiu do espaço de busca, e é aplicada a seguinte fórmula:

$$x_i = x_{min} + |x_i| \% (x_{max} - x_{min}) \quad (22)$$

Em (22), x_i é a dimensão da faísca i que saiu do espaço de busca, x_{min} é o limite inferior do espaço de busca, x_{max} é o limite superior do espaço de busca. O operador $\%$ é o operador de resto aritmético da divisão inteira entre dois valores, por exemplo, em $a \% b = c$, c é um número inteiro que resulta da divisão inteira de a entre b .

B. Geração das faíscas gaussianas

Com o objetivo de manter a diversidade da população, são criadas faíscas gaussianas cujo objetivo é melhorar a capacidade de busca global.

Para criar cada faísca gaussiana, é copiado aleatoriamente algum fogo de artifício da população, e cada um dos quais é logo deslocado em dimensões aleatórias, multiplicando-as por um número aleatório de distribuição normal com média 1 e desvio padrão 1.

C. Seleção dos indivíduos

Na seleção dos fogos de artifício da seguinte iteração, a melhor faísca ou fogo de artifício é procurado e guardado sem mudanças e os $(N_F - 1)$ fogos de artifício restantes são selecionados baseando-se numa estratégia de distância, neste caso euclidiana. Nesta estratégia, indivíduos que tenham maior distância dos outros tem maior probabilidade de formar a seguinte população de fogos de artifício. Finalmente, um método de escolha por roleta é usado para calcular a possibilidade de escolher os indivíduos.

IV. ALGORITMO DE FOGOS DE ARTIFÍCIO DE BUSCA DINÂMICA COM MUTAÇÃO DE COVARIÂNCIA

O AFABDMC [5] foi proposto como atualização dos operadores do AFA para melhorar seu desempenho e capacidade de buscas usando como base o algoritmo de fogos de artifício de busca dinâmica (AFABD) [10], o qual por sua vez é uma melhoria do AFA em relação ao algoritmo de fogos de artifício aprimorados (AFAA) [11]. Nesta seção resume-se as mudanças feitas sobre o AFA. As atualizações feitas ao AFA têm melhorado significativamente seu desempenho e capacidade de busca.

Foram atualizados a forma em que os fogos de artifício são deslocados, a forma em que a amplitude de explosão é calculada para o melhor fogo de artifício, a forma em que o mapeamento é feito, a forma em que as faíscas gaussianas são geradas e o operador de seleção de indivíduos.

A. Geração das faíscas de explosão

Tendo em vista que a busca local em torno do fogo de artifício com melhor função objetivo é muito importante para procurar o ótimo global, foi proposta uma estratégia de controle de amplitude deste fogo de artifício em particular. Suas regras são as seguintes:

Algoritmo 1 AFABDMC completo

```

1: Escolher aleatoriamente  $N_F$  fogos de artifício no
   espaço de busca para formar a população base;
2: Avaliar a função objetivo dos  $N_F$  fogos de
   artifício escolhidos;
3: Inicializar a amplitude de explosão do melhor
   fogo de artifício  $A_{CF}$  usando o tamanho do espaço
   de busca;
4: repetir
5:   Calcular o número de faíscas de explosão  $S_i$  de
   acordo com as equações (19) e (20);
6:   Calcular a amplitude de explosão  $A_i$  de cada
   fogo de artifício de acordo com a equação (21),
   exceto a do melhor fogo de artifício  $A_{CF}$ ;
7:   para cada fogo de artifício  $X_i$  fazer
8:     Gerar  $S_i$  faíscas com amplitude  $A_i$ ;
9:   fim para
10:  Avaliar a função objetivo das faíscas de
   explosão;
11:  Gerar  $N_G$  faíscas gaussianas de acordo com o
   Algoritmo 2;
12:  Avaliar a função objetivo das faíscas
   gaussianas;
13:  Calcular a amplitude de explosão do melhor
   fogo de artifício  $A_{CF}$  para a seguinte explosão;
14:  Guardar o melhor indivíduo gerado por cada um
   dos fogos de artifício para seguinte iteração
   ou ele mesmo caso as faíscas que ele gerou não
   sejam melhores;
15: até o critério de parada for satisfeito
16: retornar o melhor indivíduo e sua função objetivo.

```

- Se alguma faísca gerada na iteração atual fosse melhor que a solução incumbente, esta faísca passa à seguinte geração como o melhor fogo de artifício e a amplitude de explosão do melhor fogo de artifício A_{CF} é multiplicada por um fator de amplificação C_a para favorecer a busca global e evitar assim ficar preso em ótimos locais.
- Se todas as faíscas geradas na iteração atual forem piores que o melhor fogo de artifício da iteração atual, esse fogo de artifício passa à seguinte geração como o melhor fogo de artifício e sua amplitude de explosão A_{CF} é multiplicada por um fator de redução C_r , para favorecer a busca local em torno a este.

No AFA, o deslocamento ΔX é calculado uma vez só para todas as faíscas de explosão e logo adicionado em todas as dimensões k escolhidas por igual, isto foi mudado no AFAA para calcular um deslocamento distinto para cada dimensão e mantido no AFABDMC.

O AFA usa um operador de mapeamento de acordo à equação (22), mediante o uso do operador do módulo aritmético. Sabe-se que quando uma dimensão da faísca sai do espaço de busca, é por um valor muito pequeno e portanto o valor é muito parecido aos valores dos limites, pelo qual, existe uma tendência a remapear os indivíduos ao meio do espaço de busca. Por isso, no AFAA esse operador foi modificado para um de mapeamento com distribuição uniforme dentro do espaço de busca:

$$\hat{X}_i^k = X_{min}^k + U(0, 1) \cdot (X_{max}^k - X_{min}^k) \quad (23)$$

B. Geração das faíscas gaussianas

No AFAA, a forma em que as faíscas de explosão eram geradas mudou para assemelhar-se à forma em que no algoritmo de otimização por enxame de partículas (AEP) as partículas são atraídas pela melhor partícula, com a ideia de que isso ajudaria a busca local na posição do melhor indivíduo.

No AFABD, as faíscas gaussianas foram eliminadas pela justificativa de que sua função de busca global estava sendo redundante pelo fato de que esta estava sendo realizada pelos fogos de artifício que tinham pior função objetivo e portanto maior amplitude de explosão. Após análises, concluíram que estas faíscas não contribuíam à convergência do algoritmo.

No AFABDMC estas foram incluídas novamente para ajudar à busca local em torno das melhores faíscas em cada iteração e foi empregada uma estratégia de mutação de covariância para criá-las.

Para implementar esta estratégia, após as faíscas de explosão forem criadas, é criado um *cluster* que agrupa o melhor fogo de artifício da presente geração e as faíscas de explosão geradas por ele. A seguir, é criado um novo *cluster* com os μ melhores indivíduos do *cluster* anterior, sendo μ um número criado em base ao tamanho do *cluster* anterior usando alguma porcentagem, é sugerido usar uma porcentagem de 50 a 75%. Em seguida, é calculada a média desse segundo *cluster* como:

$$m = \sum_{i=1}^{\mu} (w_i \cdot x_i) \quad (24)$$

$$w_i = \frac{1}{\mu} \quad (25)$$

Em (24)–(25), m é a média do *cluster* de indivíduos, μ é o número de indivíduos no novo *cluster* e w_i é representa o peso do indivíduo i do *cluster*.

Em seguida, é calculada a matriz de covariância C :

$$\begin{pmatrix} cov(d_1, d_1) & cov(d_1, d_2) & \cdots & cov(d_1, d_D) \\ cov(d_2, d_1) & cov(d_2, d_2) & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ cov(d_D, d_1) & \cdots & \cdots & cov(d_D, d_D) \end{pmatrix} \quad (26)$$

Em (26), $cov(d_i, d_j)$ representa a covariância entre as dimensões i e j .

$$cov(d_1, d_2) = \frac{\sum_{i=1}^D ((d_1 - \bar{D}_1)(d_2 - \bar{D}_2))}{D} \quad (27)$$

Em (27), $\bar{D}_1$ e $\bar{D}_2$ são os valores médios das dimensões d_1 e d_2 .

C. Seleção de indivíduos

No AFAA e no AFABD foi considerado adequado mudar a estratégia de seleção do AFA para a seleção elitista aleatória [12] que tem menor custo computacional a qual baseia-se na preservação do melhor indivíduo e a escolha dos demais $N-1$ indivíduos de forma aleatória.

Após uma análise deste operador, notou-se que esta não garante a preservação dos melhores indivíduos da população e

Algoritmo 2 Gerando as “faíscas gaussianas” no AFABDMC

- 1: Gerar um *cluster* K_1 incluindo o melhor fogo de artifício da geração atual e as faíscas de explosão que este gerou na iteração atual
- 2: Gerar o *cluster* K_2 incluindo os μ melhores indivíduos do *cluster* K_1
- 3: Calcular a média m do *cluster* K_2 de acordo as equações (24) e (25)
- 4: Calcular a matriz de covariância C do *cluster* K_2 de acordo as equações (26) e (26)
- 5: **para cada** faísca gaussiana gerada $\hat{X}_k$ **fazer**
- 6: Gerar uma faísca gaussiana X_k com média m e usando a matriz de covariância C
- 7: **fim para**

por isso não se aproveita as avaliações da função objetivo já realizadas.

No AFABDMC, foi proposta uma estratégia que divide a população em grupos, cada um deles correspondente a cada um dos fogos de artifício da população base. Após uma iteração, é feita uma seleção do melhor indivíduo de cada grupo, o qual passa a ser o fogo de artifício correspondente para a seguinte iteração. Esta nova estratégia tem como vantagem manter a diversidade da população e ao mesmo tempo evitar a seleção de soluções de baixa qualidade para a seguinte iteração.

V. IMPLEMENTAÇÃO DO ALGORITMO

Normalmente, o problema do FPO é resolvido como um problema de PNLIM, mas neste trabalho, o problema é dividido em otimização inteira pelo uso do AFABDMC, no qual, fixando a parte inteira dos *taps* dos transformadores e estado do conexão dos reatores *shunt*, é chamado o *solver* KNITRO no AMPL para resolver o problema de PNL de otimização das variáveis de geração de potência ativa e tensão nas barras geradoras. O AMPL [13], pelo AMPL API, devolve ao MATLAB o valor da função objetivo, obtido pelo KNITRO [14], para as decisões que devem ser tomadas pelo AFABDMC.

O AFABDMC teve de ser adaptado para a otimização de variáveis inteiras já que originalmente foi proposto para a otimização de variáveis contínuas. Para isto, tiveram de ser incluídos valores de amplitude de explosão mínimos separadamente, usando 3 para a amplitude de explosão das variáveis inteiras de *taps* de transformados, as quais têm valores entre -16 e 16 e usando $0,75$ para a amplitude de explosão de variáveis binárias, para assegurar que estas mudem de estado no processo de otimização. Uma vez que novas faíscas são geradas, estas são arredondadas.

A inicialização da população inicial de fogos de artifício começa com todos os valores de *taps* e os valores binários de conexão/desconexão de reatâncias *shunt* aleatórios.

Os parâmetros do algoritmo AFABDMC usados foram:

- Tamanho da população: $N_F = 5$;
- Número de faíscas de explosão: $\hat{S} = 15$;
- Número de faíscas gaussianas: $N_G = 5$;
- Número mínimo de faíscas de explosão: $\hat{S}_{min} = 3$;
- Número máximo de faíscas de explosão: $\hat{S}_{max} = 8$;
- Constante de amplitude: $\hat{A} = 0,6250$;

- Amplitude mínima de explosão: $\hat{A}_{min} = 4$;
- Amplitude máxima de explosão: $\hat{A}_{max} = 8$;
- Amplitude de explosão das var. binárias: $\hat{A}_{bin} = 0,75$;
- Constante de redução de amplitude: $C_r = 0,9$;
- Constante de amplificação de amplitude: $C_a = 1,1$;
- Probabilidade de mudança das dimensões: $MR = 0,2$.

VI. TESTES E RESULTADOS

As características dos sistemas IEEE usados no presente trabalho são mostradas na Tabela I [15]. Sendo que as variáveis otimizadas pelo AFABDMC são as variáveis contínuas de *tap* dos transformadores variáveis e as variáveis binárias de *shunts* chaveados.

Tabela I: Características dos sistemas testados

Sistema	IEEE 57 Barras	IEEE 118 Barras
Geradores	4	54
Cargas	42	91
Linhas	80	186
Transformadores com <i>tap</i> variável	17	9
<i>Shunts</i> chaveados	3	14

O AFABDMC foi utilizado para resolver o problema. Para comparar os resultados, o *solver* KNITRO [14] foi aplicado diretamente ao problema de PNLIM. Os resultados obtidos são mostrados na Tabela II.

Tabela II: Resultados Obtidos pelo AFABDMC e KNITRO [US\$]

Sistema IEEE	AFABDMC	KNITRO
57 barras	272.4810606	272.4780138
118 barras	966.8039887	966.8027550

Os resultados da Tabela II demonstram que o AFABDMC encontrou soluções próximas às obtidas pelo KNITRO aplicado diretamente ao problema de PNLIM.

Na Figura 1 ilustra-se a evolução da metodologia no caso do sistema IEEE de 57 barras, na qual, em 10 testes independentes, na média, foram encontradas soluções de boa qualidade em 500 resoluções de problemas de PNL. Como o sistema apresenta alta complexidade em relação ao espaço de busca da metodologia, foram utilizadas 2500 avaliações da função objetivo. Como a diferença na função objetivo no caso da melhor dos 10 testes em relação ao ótimo global encontra-se na segunda casa decimal, em termos práticos as soluções são de qualidade semelhante.

Na Figura 2 mostra-se a evolução da metodologia no caso do sistema IEEE de 118 barras, na qual, em 10 testes independentes, foram encontradas soluções de boa qualidade desde o começo do processo. Como o sistema apresenta complexidade média em relação ao espaço de busca da metodologia, foram utilizadas 1500 avaliações da função objetivo, sendo que cada problema de PNL é resolvido em maior tempo do que no sistema IEEE de 57 barras. Como a diferença na função objetivo encontra-se na terceira casa decimal, em termos práticos as soluções são de igual qualidade.

Para casos em que o FPO precise ser calculado em tempo real e sejam requeridos tempos de otimização menores aos da resolução do modelo de PNLIM, as primeiras soluções

de boa qualidade do AFABDMC podem ser usadas. Pela análise das populações finais de fogos de artifício ao final do processo de otimização, verifica-se que quase todos os melhores indivíduos convergiram para soluções próximas ao ótimo global, mas com configurações de *taps* muito distintas, oferecendo mais de uma possibilidade para a reconfiguração destes dispositivos. Pela estratégia de seleção do AFABDMC, cada fogo de artifício representa um ótimo local distinto que é explorado pelo processo de “explosão” que pode ser aproveitado.




Figura 1: Otimização do sistema de IEEE de 57 barras.




Figura 2: Otimização do sistema de IEEE de 118 barras.

VII. CONCLUSÕES

A meta-heurística AFABDMC apresenta um bom desempenho dentro da metodologia na otimização de variáveis inteiras e binárias no problema do FPO, obtendo soluções de boa qualidade desde as primeiras chamadas à função objetivo. Esta meta-heurística apresenta uma boa implementação de estratégias de intensificação e diversificação.

Tiveram de ser adicionados parâmetros de controle na meta-heurística AFABDMC para adaptá-la à otimização de variáveis inteiras.

A metodologia tem a vantagem de aproveitar a potência computacional do *solver* KNITRO para otimizar as variáveis contínuas de controle, a diferença de outras metodologias nas quais a meta-heurística otimiza todas as variáveis e tem problemas em otimizar as variáveis contínuas com vários dígitos significativos. O avanço na otimização computacional

do *solver* comercial KNITRO permite a resolução de problemas de PNL em tempos de processamento aceitáveis.

A partir do trabalho de pesquisa desenvolvido neste trabalho podem ser sugeridos como trabalhos futuros:

- Idealizar melhores operadores na meta-heurística AFABDMC para sua adaptação à otimização de variáveis inteiras;
- O método usado pode ser adaptado para resolver problemas correlatos que apresentem a mesma estrutura matemática, como o planejamento e operação de sistemas de distribuição ou de transmissão de energia elétrica;
- Implementar a meta-heurística AFABDMC em uma linguagem de mais baixo nível para reduzir o tempo computacional;
- Rodar a meta-heurística em paralelo para obter várias soluções elite e assim oferecer várias opções para sua implementação na prática.

AGRADECIMENTOS

Os autores agradecem à CAPES e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo nº 2014/23741-9, pelo apoio financeiro.

REFERÊNCIAS

- [1] J. L. Carpentier, “Contribution a l’etude du dispatching economique,” in *1962 Bulletin de la Societe Francaise des Electriciens*, pp. 431–447.
- [2] S. Frank, I. Steponavice, and S. Rebennack, “Optimal power flow: a bibliographic survey I” *Energy Systems*, vol. 3, no. 3, pp. 221–258, Sep. 2012.
- [3] S. Frank, I. Steponavice, and S. Rebennack, “Optimal power flow: a bibliographic survey II” *Energy Systems*, vol. 3, no. 3, pp. 259–289, Sep. 2012.
- [4] Y. Tan, Y. Shi, and K. C. Tan, “Fireworks algorithm for optimization,” in *Advances in swarm intelligence: Lecture notes in computer science*, Berlin: Springer-Verlag, 2010, pp. 355–364.
- [5] C. Yu, L. C. Kelley, and Y. Tan, “Dynamic search fireworks algorithm with covariance mutation for solving the CEC 2015 learning based competition problems,” in *2015 IEEE Congress on Evolutionary Computation*, pp. 1106–1112.
- [6] J. Zhu, *Optimization of power system operation*. 2nd ed. Hoboken: John Wiley & Sons, 2015.
- [7] M. A. Abido, “Optimal power flow using particle swarm optimization,” *Int. J. Elec. Power*, vol. 24, no. 7, pp. 563–571, Oct. 2002.
- [8] C. M. Huang, S. J. Chen, Y. C. Huang, and H. T. Yang, “Comparative study of evolutionary computation methods for active-reactive power dispatch,” *IET Gen., Tran. & Dist.*, vol. 6, no. 7, pp. 636–645, Jul. 2012.
- [9] Y. Tan, *Fireworks algorithm: a novel swarm intelligence optimization method*. Berlin: Springer-Verlag, 2015.
- [10] S. Zheng, A. Janacek, J. Li, and Y. Tan, “Dynamic search in fireworks algorithm” in *2014 IEEE Congress on Evolutionary Computation*, pp. 3222–3229.
- [11] S. Zheng, A. Janacek, and Y. Tan, “Enhanced fireworks algorithm,” in *2013 IEEE Congress on Evolutionary Computation*, pp. 2069–2077.
- [12] A. P. Engelbrecht, *Fundamentals of computational swarm intelligence*. Hoboken: John Wiley & Sons, 2006.
- [13] R. Fourer, D. M. Gay, and B. W. Kernighan, *AMPL: a modeling language for mathematical programming*. 2nd ed. Pacific Grove: Brooks/Cole-Thomson Learning, 2003.
- [14] R. H. Byrd, J. Nocedal, and R. A. Waltz, “KNITRO: an integrated package for nonlinear optimization,” in *Large-Scale Nonlinear Optimization*. New York: Springer-Verlag, 2006, pp. 35–59.
- [15] I. Erlich, K. Y. Lee, J. L. Rueda, and S. Wildenhues, “Competition on application of modern heuristic optimization algorithms for solving optimal power flow problems,” in *2014 IEEE Power Engineering Society General Meeting*.