

ANÁLISE COMPARATIVA DE META-HEURÍSTICAS NO BALANCEAMENTO DE CARGAS EM REDES DE DISTRIBUIÇÃO

JOSÉ D. ANZANELLO JR*, EDUARDO COSTA BRAGA*, SÉRGIO HAFFNER*, ANALIZA DALLA COSTA*

**Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal do Rio Grande do Sul (UFRGS)
Porto Alegre, RS, Brasil*

Emails: anzanello.junior@ufrgs.br, eduardo.braga@ufrgs.br, haffner@ieee.org, analizadallac@gmail.com

Abstract— This article proposes a comparative analysis between Artificial Bee Colony and Genetic Algorithm metaheuristics with Random Search, applied to load balancing problems in electrical energy distribution networks. The objective is to determine the best way to connect different classes of consumers to the system buses, where is desired the combination which results in the lowest annual loss of energy. The model was implemented with the integration of MATLAB[®] and OpenDSS software. The methodology was validated through the optimization methods proposed in a low voltage distribution network.

Keywords— Artificial Bee Colony, Genetic Algorithm, Load Balancing, Losses Minimization, OpenDSS.

Resumo— O presente artigo propõe uma análise comparativa entre as meta-heurísticas Colônia Artificial de Abelhas e Algoritmo Genético com a Busca Aleatória, aplicadas ao problema de balanceamento de cargas em redes de distribuição de energia elétrica. O objetivo é determinar a melhor maneira de conectar diferentes classes de consumidores nas barras do sistema, na qual é desejada a combinação que resulta na menor perda de energia anual. O modelo foi implementado com a integração dos softwares MATLAB[®] e OpenDSS. A metodologia foi validada através dos métodos de otimização propostos em uma rede de distribuição de baixa tensão.

Palavras-chave— Colônia Artificial de Abelhas, Algoritmo Genético, Balanceamento de cargas, Minimização de perdas, OpenDSS.

1 Introdução

Diversas são as consequências do desbalanceamento de cargas em sistemas de distribuição de energia elétrica, visto que dificilmente o sistema irá operar de forma estritamente balanceada já que o consumo varia constantemente. Entre estas consequências, se destacam o desequilíbrio nas tensões e perdas de energia acentuadas. Em geral, os custos decorrentes destas perdas são divididos entre a distribuidora e os consumidores, o que propicia um incentivo econômico às distribuidoras para que busquem reduzi-las em seus sistemas elétricos e, assim, aumentar o seu lucro (ANEEL, 2017).

Frente ao exposto, verifica-se a importância de manter a rede elétrica com as cargas distribuídas o mais próximo possível do equilíbrio. Para atingir tal objetivo, diversas metodologias podem ser aplicadas. A reconfiguração de alimentadores e a reconexão de cargas entre fases são estratégias utilizadas para equilibrar sistemas (Civanlar et al., 1988), (Zhu et al., 1998). Entretanto, no caso da reconexão de cargas entre fases, mesmo se tratando de circuitos de pequenas proporções, o número de combinações para conexão de cada consumidor é bastante elevado, tornando o processo de enumeração muitas vezes inviável. Para resolver este tipo de problema de otimização o emprego de métodos heurísticos mostra-se adequado (Zhu et al., 1998).

Os algoritmos genéticos (AG) têm sido aplicados para otimizar a distribuição de cargas entre fases, minimizando perdas em sistemas de

distribuição (Ravibabu et al., 2008), (Chen e Cherng, 2000) e (Nara et al., 1992). Outros artigos fazem uso do método baseado em Colônia Artificial de Abelhas (do inglês *Artificial Bee Colony*, ABC). Kouba et al. (2015) propõe o uso do ABC para controlar a frequência do sistema e Linh e Anh (2010) realizam reconfiguração de redes com o objetivo de reduzir perdas.

As principais contribuições deste trabalho são as seguintes: i) a codificação empregada que reduz o espaço de busca e permite representar apenas formas de conexão atrativas; ii) é realizada uma análise estatística da eficiência de duas meta-heurísticas bastante utilizadas e iii) o ABC e o AG são comparados entre si e com a busca aleatória, considerando o mesmo problema de otimização.

2 Modelagem do problema

O balanceamento de cargas em redes de distribuição é um problema de natureza combinatória e não-linear. Geralmente, a função objetivo utilizada é a minimização das perdas e mesmo em um sistema de dimensões reduzidas, o problema combinatório associado pode ser intratável por meio de métodos enumerativos. Desta forma, o emprego de métodos heurísticos ou meta-heurísticas é recomendável. Uma etapa fundamental no emprego dos métodos heurísticos é definir uma forma eficiente de representar o problema de otimização. Além disso, é indispensável definir o modo pelo qual os operadores dos métodos utilizados serão implementados, considerando a representação utilizada.

2.1 Codificação empregada

Visando obter uma representação que seja aplicável a problemas de balanceamento de cargas em sistemas de distribuição, foram definidos padrões de conexão (PC) e padrões de fase (PF). Nesta representação são reproduzidas apenas soluções viáveis e de boa qualidade.

O PC descreve quais consumidores estão conectados em cada uma das fases do sistema. Para um sistema trifásico, tal padrão deve dizer quais consumidores estão conectados nas fases 1 a 3 para todos os nós da rede. Para limitar a busca a soluções atrativas, os PCs são definidos de modo que as cargas fiquem razoavelmente distribuídas entre as fases, evitando assim que em cada nó da rede ocorra algum desequilíbrio acentuado.

O PF indica qual fase do sistema deve estar conectada a cada fase do PC. Neste trabalho, todos os 6 PFs possíveis (do sistema trifásico), foram considerados, conforme mostrado na Tabela 1, onde as colunas 2 a 4 indicam as fases do sistema (A,B ou C) que devem estar conectadas as fases 1,2 ou 3 do PC. Cada linha desta Tabela representa um PF.

Tabela 1: Enumeração dos padrões de fase para um sistema trifásico.

PF	Fase 1	Fase 2	Fase 3
1	A	B	C
2	A	C	B
3	B	A	C
4	B	C	A
5	C	A	B
6	C	B	A

A representação da conexão dos consumidores nas fases do sistema e em todos os seus nós é realizada por intermédio de um vetor com dimensão $2N$, sendo N o número de nós com carga da rede. Para cada nó, são usadas duas posições, uma para o PC e outra para o PF, conforme mostrado na Figura 1, na qual o PC varia de 1 a PC_n , sendo PC_n o número de PCs atrativos para o nó n , e o PF varia de 1 a 6.

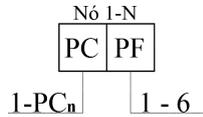


Figura 1: Representação dos padrões de conexão e de fase.

O PC_n depende dos tipos de consumidores que estão conectados ao nó n , sendo enumeradas todas as formas de conexão nas quais a carga esteja relativamente distribuída entre as fases.

2.2 Modelagem do Problema através do algoritmo ABC

Na codificação das fontes de alimento, que representam uma possível solução para o problema,

cada nó do sistema é representado por duas posições, as quais reproduzem um padrão de conexão e um padrão de fase conforme a Figura 1. A Figura 2 exemplifica a representação de uma fonte de alimento inicial, gerada de maneira aleatória.

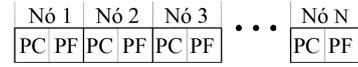


Figura 2: Representação de uma fonte de alimento da colônia.

2.2.1 Inicialização e fase das abelhas campeiras

A inicialização do algoritmo ABC consiste na geração das fontes de alimentos de maneira aleatória, em conformidade com os PCs e PFs de cada nó. Na sequência, cada abelha campeira é alocada em uma fonte de alimento, pois o número de abelhas campeiras é igual ao número de fontes de alimento. Com isso, é realizada a avaliação da função objetivo de cada fonte de alimento e estas são ordenados de forma crescente.

2.2.2 Fase das abelhas recrutadoras

A utilização de abelhas recrutadoras é uma adaptação ao modelo clássico do ABC (Karaboga, 2005). O intuito de adicioná-las é evitar a estagnação em mínimos locais e melhorar o desempenho computacional do código, uma vez que no ABC originalmente proposto todas as abelhas campeiras são recrutadoras.

É realizada uma busca em vizinhança em torno das 15% melhores fontes de alimento correspondentes às abelhas campeiras com melhores valores de função objetivo, as quais passam a ser abelhas recrutadoras. Cada posição do vetor fonte de alimento, relativo a enumeração dos padrões de conexão e de fase dos nós do sistema, sofre uma alteração de +1, respeitando os limites dos padrões. Caso seja verificada uma melhora na função objetivo, o valor da posição que obteve esta melhora, é substituído.

2.2.3 Fase das abelhas seguidoras

Nesta fase, cada abelha seguidora, correspondente a 65% da colônia, segue a recrutadora vencedora de um torneio realizado entre dois participantes. Após, faz-se um laço percorrendo n_{viz} (número de vizinhos) da fonte de alimento, sorteia-se uma posição neste vetor e um valor para esta posição, respeitando os limites dos PCs e PFs. Se houver uma melhora na função objetivo, o valor da posição é alterado. Caso contrário, uma nova posição é sorteada.

2.2.4 Fase das abelhas exploradoras

O término da iteração do ABC se dá com as 20% piores fontes de alimento eliminadas para dar lu-

gar a novas fontes geradas de maneira aleatória. A melhor solução obtida é armazenada e caso o número de iterações não tenha atingido o limite estipulado, o processo iterativo prossegue.

2.3 Modelagem do problema através do algoritmo genético

Esta seção apresenta o modo pelo qual os operadores utilizados nos algoritmos genéticos foram implementados neste trabalho.

2.3.1 População inicial

Na codificação dos indivíduos, cada um dos nós é representado por dois genes, os quais reproduzem um PC e um PF, conforme Figura 1. No modelo implementado, os indivíduos são gerados de modo aleatório, considerando as possibilidades definidas pelos PCs e PFs de cada nó da rede. Tanto os PCs quanto os PFs são gerados de modo uniformemente distribuído.

2.3.2 Seleção dos indivíduos

As novas gerações populacionais seguem um método de reposição de acordo com a aplicação de operadores genéticos de seleção, recombinação e mutação. A seleção é realizada por meio de torneio entre três indivíduos da população atual.

2.3.3 Operador de recombinação

Após a seleção dos pais, aplica-se primeiramente o operador genético de recombinação, com um ou dois pontos de corte, sendo os pontos de corte gerados de maneira aleatória.

2.3.4 Operador de mutação

O operador genético de mutação altera o valor de um conjunto de genes por outro conjunto gerado de forma aleatória. Dessa maneira, novas informações são inseridas na população, possibilitando novas combinações e um aumento na probabilidade de se obter uma solução otimizada. A posição dos genes e seu valor são definidos aleatoriamente, abrangendo de um a dois nós.

3 Aplicação do modelo proposto

Nesta seção, são apresentados os resultados dos testes realizados utilizando as duas metodologias heurísticas de otimização descritas anteriormente. Para tanto, foi utilizado um sistema de distribuição de 9 barras, mostrado na Figura 3. A rede de baixa tensão é trifásica e possui nove nós e oito circuitos, operando em 220 V.

O transformador que alimenta a rede tem potência de 75 kVA e as cargas foram modeladas como 50% potência constante e 50% impedância constante. Cada circuito de distribuição corresponde a 30 metros de rede aérea em estrutura convencional, com impedância de sequência positiva igual a $0,0210 + j0,0115 \Omega$.

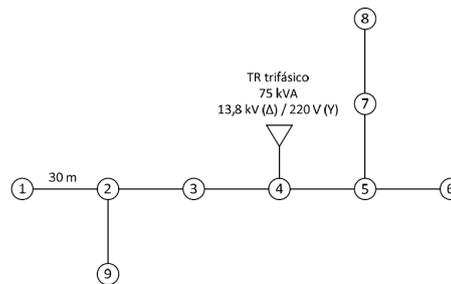


Figura 3: Diagrama do sistema de distribuição em baixa tensão.

Para exemplificar a caracterização da carga, foram considerados cinco tipos de consumidores: dois monofásicos, dois bifásicos e um trifásico. A Tabela 2 mostra as demandas de potência associadas a cada tipo de consumidor, considerando três patamares de consumo (referentes a carga pesada, média e leve). Por simplicidade, assume-se que tais patamares ocorrem de modo simultâneo em todos os consumidores. O fator de potência considerado para todos consumidores é igual a 0,85 em atraso (indutivo). Também na Tabela 2 é mostrada a duração anual em horas de cada patamar de consumo.

Tabela 2: Demanda das classes de consumidores.

Tipo de consumidor	Demanda de potência			
	Nominal[VA]	Pesada [%]	Média [%]	Leve [%]
M1	1000	100	40	10
M2	1300	100	40	10
B1	1800	100	40	10
B2	2500	100	40	10
T	3600	100	40	10
Duração [h/ano]		1095	4745	2920

O número de consumidores de cada tipo que está conectado em cada nó é mostrado na Tabela 3.

Tabela 3: Número de consumidores de cada tipo conectados aos nós.

Nós	Número de consumidores conectados				
	Monofásico		Bifásico		Trifásico
	M1	M2	B1	B2	T
1,6,8 e 9	1	1	1	1	1
2 e 3	2	1	1	1	
4,5 e 7	1	2	1	1	
Total	11	12	9	9	4

A função objetivo adotada é a minimização das perdas anuais de energia, que é dada por:

$$\min E_{perdas} = \min \sum_c T^c \left(\sum_{km} P_{km}^c + \sum_{tr} P_{tr}^c \right) \quad (1)$$

onde c é o nível de carregamento cuja duração é dada em horas por ano, T^c é dada na Tabela 2; P_{km}^c é a perda de potência ativa no circuito km , durante o carregamento c e P_{tr}^c é a perda

de potência ativa no transformador tr durante o carregamento c . A determinação das perdas nos circuitos e no transformador é realizada por intermédio da integração do *software* OpenDSS com o MATLAB®.

Como referência para o valor mínimo das perdas, foi realizada a simulação do algoritmo de fluxo de potência da rede de distribuição no cenário em que todas as cargas são distribuídas uniformemente entre as fases. Para esta situação inatingível, foi obtido o valor para as perdas de 5503,79 kWh/ano. Cabe salientar que essa solução é inactível devido às diferentes demandas dos cinco tipos de consumidores adotados na modelagem do problema, como visto na Tabela 3.

O espaço de busca do problema tem relação direta com a codificação adotada. Como visto na Seção 2.1, a adoção de PCs e PFs limita as combinações a apenas soluções factíveis e atrativas. A Tabela 4 representa o conjunto de possibilidades de conexão para cada nó.

Tabela 4: Conjunto de possibilidades de conexão para cada nó da rede de distribuição.

Nós	PC	PF	Combinações
1,6,8 e 9	11	6	66
2 e 3	16	6	96
4,5 e 7	16	6	96

Desta forma, o número de possibilidades de conexão para todas as cargas do sistema é dado pela seguinte expressão :

$$NP = 66^4 \times 96^2 \times 96^3 \approx 1,55 \times 10^{17} \quad (2)$$

3.1 Aplicação do Algoritmo ABC

O modelo proposto foi implementado utilizando os parâmetros mostrados na Tabela 5.

Tabela 5: Parâmetros adotados no algoritmo ABC.

Parâmetro	Valor
Número de Ciclos de busca (n_{it})	100
Número de fontes de alimento (n_{food})	200
Número de Abelhas Campeiras = n_{food}	200
Taxa de Abelhas Recrutadoras (recruited)	15%
Taxa de Abelhas Seguidoras (onlookers)	65%
Taxa de Abelhas Escudeira (scouts)	20%
Vizinhos explorados por Abelha Seguidora (n_{viz})	5
Participantes do Torneio	2

Em diversas simulações utilizando os parâmetros da Tabela 5, o menor valor obtido para a energia de perdas total foi de 5844,43 kWh/ano (cerca de 6,2% maior do que a solução que considera as cargas equilibradas).

Para a definição dos parâmetros mostrados na Tabela 5, foram realizadas simulações variando o número de fontes de alimento. A Figura 4 mostra o histograma das melhores soluções obtidas em

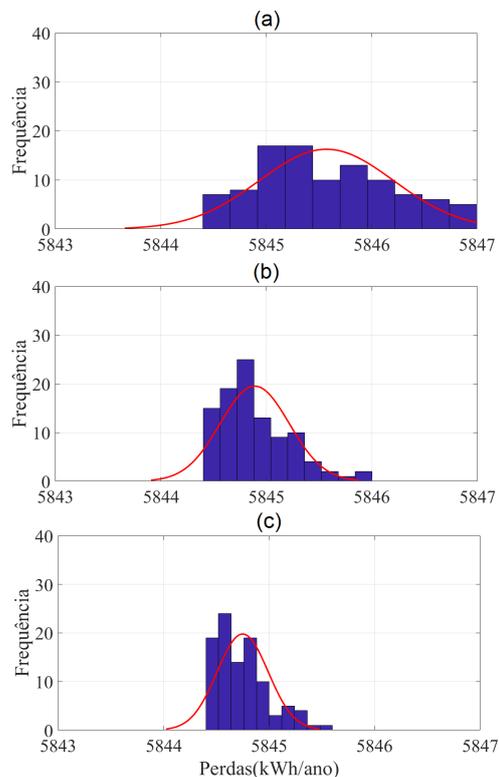


Figura 4: Histograma e curva de distribuição normal sobreposta para amostras de colônias com: (a) 20, (b) 100 e (c) 200 fontes de alimento.

100 execuções do ABC com a variação do número de fontes de alimento empregadas entre 20 e 200.

Com o incremento do número de fontes de alimento, é realizada uma maior varredura no espaço de busca, o que propicia a obtenção de soluções com menor valor de perdas. Devido a vasta dimensão deste espaço, a solução incumbente final é em parte dependente da posição inicial das fontes de alimento, a qual é determinada de forma aleatória através dos PCs e dos PFs. O quão mais próxima da melhor solução for a posição inicial da fonte de alimento, mais rápida é a convergência (menor número de ciclos de busca) e maior a chance de obtenção desta solução.

A avaliação da variação do número de vizinhos avaliados por abelha seguidora, juntamente com a variação do número de fontes de alimento está mostrada na Tabela 6. Variando o número de vizinhos avaliados pelas abelhas seguidoras, foram realizadas 50 execuções do algoritmo com 100 e 200 fontes de alimento. Com isso, foram obtidos os valores da melhor solução encontrada, a média das soluções e o desvio padrão, mostrados nas colunas 3, 4 e 5 respectivamente.

Nota-se que o número de vizinhos avaliados por abelha seguidora, após 5 avaliações, gera pouca melhora nos índices de energia de perdas obtidos, tanto para 100 como para 200 fontes de alimento. No entanto, há um incremento no tempo de execução e, por esse fato, foi adotado o

Tabela 6: Energia de perdas pela variação do número de fontes de alimento e de vizinhos explorados por abelha seguidora.

n_{food}	n_{viz}	Energia de perdas [kWh]		
		melhor solução	média	desvio padrão
100	1	5844,548	5845,601	1,064
	3	5844,504	5845,010	0,525
	5	5844,439	5845,009	0,511
	10	5844,433	5844,935	0,547
200	1	5844,618	5845,254	0,391
	3	5844,441	5844,780	0,251
	5	5844,433	5844,749	0,242
	10	5844,433	5844,686	0,238

valor de $n_{viz} = 5$ para as simulações.

3.2 Aplicação do AG

O modelo proposto foi resolvido de forma similar através do Algoritmo Genético, no qual foram utilizados os parâmetros mostrados na Tabela 7.

Tabela 7: Parâmetros adotados no algoritmo genético.

Parâmetro	Valor
Número de Gerações (n_{ger})	200
Número de Indivíduos (n_{ind})	200
Taxa de Recombinação	40%
Taxa de Mutação	35%
Indivíduos na Elite	2
Participantes do Torneio	3

A Figura 5 mostra o histograma das melhores soluções obtidas em 100 execuções do AG, variando a população de 20 a 200 indivíduos.

A avaliação da variação do número de indivíduos e de gerações, para 50 execuções do algoritmo, está mostrada na Tabela 8. Com isso, foram obtidos os valores da melhor solução encontrada, a média das soluções e o desvio padrão, mostrados nas colunas 3, 4 e 5 respectivamente.

Tabela 8: Energia de perdas pela variação do número de gerações e da população.

n_{ger}	n_{pop}	Energia de perdas [kWh]		
		melhor solução	média	desvio padrão
100	20	5844,839	5845,650	0,893
	100	5844,507	5845,120	0,437
	200	5844,433	5844,805	0,245
200	20	5844,603	5845,212	0,588
	100	5844,433	5844,858	0,286
	200	5844,433	5844,651	0,190

Nota-se que o incremento no número de gerações, de 100 para 200, propicia a obtenção de melhores valores médios e uma redução do desvio padrão nos índices de energia de perdas obtidos.

De forma semelhante, também foi realizada uma análise de sensibilidade com os demais parâmetros do AG para verificar a probabilidade de obter a solução almejada com um menor esforço computacional. No entanto, ao variar as taxas de

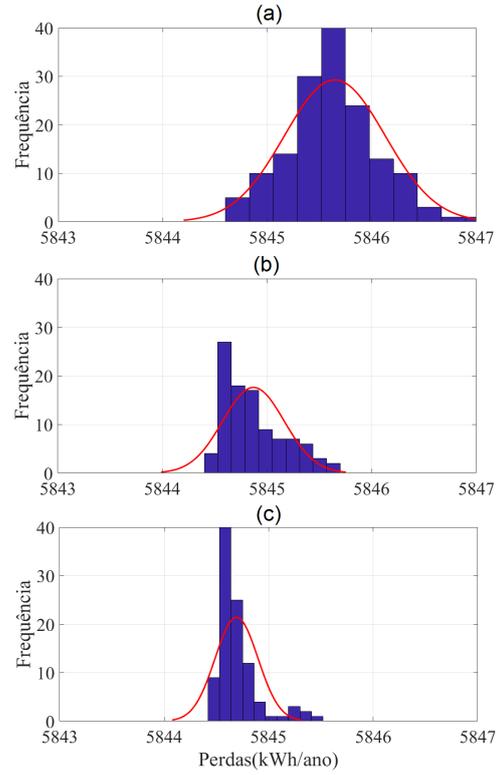


Figura 5: Histograma e curva de distribuição normal sobreposta para amostras de população com: (a) 20, (b) 100 e (c) 200 indivíduos.

mutação, recombinação e elitismo, a solução referência apresentou mudanças muito pequenas.

3.3 Comparação entre os algoritmos

Uma avaliação de desempenho entre o algoritmo ABC e o algoritmo AG é mostrada pela Figura 6. Nesta figura, são avaliadas as curvas de distribuição normal para amostras com 20 e 40 mil avaliações da função objetivo. Nota-se que para 20 mil avaliações, o ABC tem convergência aquém do AG. Entretanto, na amostra com 40 mil avaliações, o ABC obteve uma curva de distribuição mais próxima da normal e similar a do AG, com convergência no entorno da melhor solução obtida.

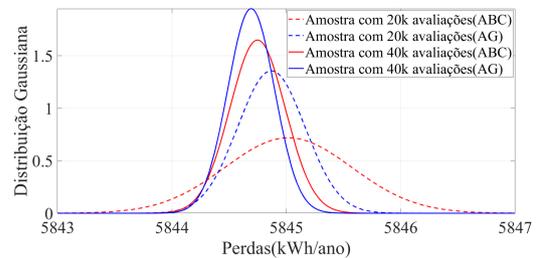


Figura 6: Comparação entre os algoritmos AG e ABC.

A Figura 7 ilustra a comparação da evolução de convergência da solução incumbente em 5 execuções do AG e em 5 execuções do ABC. Para equiparar o número de avaliações da função objetivo entre os métodos, foi reduzido o número de

iterações do ABC de 100 para 86, mantendo os demais parâmetros das Tabelas 5 e 7.

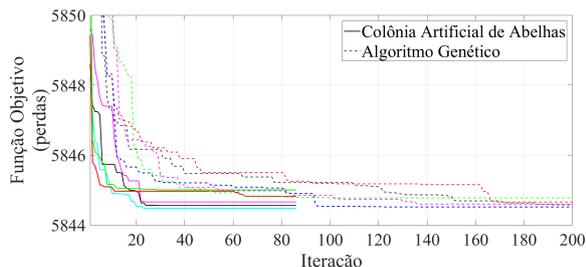


Figura 7: Avaliação da evolução de convergência de 10 amostras dos algoritmos ABC e AG.

Com os parâmetros adotados para os dois algoritmos, o AG demonstrou obter soluções próximas a melhor solução obtida com maior frequência que o ABC. Por outro lado, observa-se que o ABC converge mais precocemente, mas para valores de função objetivo de qualidade um pouco inferior.

Para ampliar o espectro da avaliação, os resultados obtidos pelo ABC e pelo AG foram comparados com os resultados da busca aleatória. A Tabela 9 mostra os resultados obtidos variando-se o número de amostras de 10^3 a 10^6 . Com isso, foram obtidos os valores da melhor solução encontrada, a média das soluções e o desvio padrão, mostrados nas colunas 2, 3 e 4 respectivamente. Pode-se observar que o valor médio da energia de perdas obtida está aquém dos valores obtidos pelas meta-heurísticas AG (avaliando 40 mil indivíduos) e ABC (avaliando menos de 50 mil fontes de alimento), o que exalta a eficácia das mesmas.

Tabela 9: Energia de perdas pela busca aleatória.

iterações	Energia de perdas [kWh]		
	melhor solução	média	desvio padrão
10^3	5861,53	5943,12	51,24
10^4	5853,00	5942,27	51,14
5×10^4	5851,39	5942,66	51,44
10^5	5848,79	5942,42	51,20
5×10^5	5846,50	5942,39	51,35
10^6	5845,41	5942,28	51,24

4 Conclusão

A partir dos resultados obtidos verifica-se que os métodos de otimização desenvolvidos, com base no ABC e no AG, são uma boa abordagem para o estudo da minimização de perdas em sistemas de distribuição de energia elétrica através do balanceamento de cargas. Este problema de balanceamento é não convexo e apresenta diversos mínimos locais, dificultando a aplicação de métodos de otimização matemática ou baseados em busca local.

A representação do problema por intermédio dos PCs e PFs foi determinante para propiciar um bom desempenho dos algoritmos, inclusive da busca aleatória, cuja dispersão dos resultados foi

bastante reduzida, indicando que soluções consideradas apresentavam qualidade bastante similar. Esta representação, além de reduzir o espaço de busca, permitiu que as soluções mapeadas apresentassem boa qualidade, podendo ser útil para outras classes de problemas com natureza similar.

Durante as simulações, foram realizadas inúmeras avaliações com o objetivo de verificar quais os parâmetros ofereciam a maior probabilidade de obter a solução almejada com o menor esforço computacional. Entretanto, frente aos parâmetros adotados no ABC e no AG, o aumento das fontes de alimento e a elevação do número de indivíduos, respectivamente, foram os que tiveram maior influência na obtenção de resultados mais próximos da melhor solução obtida. O algoritmo AG apresentou melhores resultados que o ABC ao equiparar o número de avaliações da função, mas com uma variação muito pequena.

Agradecimentos

Agradecemos ao CNPq e a CAPES pelo auxílio financeiro, o qual possibilitou a realização deste trabalho.

Referências

- ANEEL (2017). Metodologia de cálculo tarifário da distribuição - perdas de energia.
- Chen, T.-H. e Cherng, J.-T. (2000). Optimal phase arrangement of distribution transformers connected to a primary feeder for system unbalance improvement and loss reduction using a genetic algorithm, *IEEE Transactions on Power Systems* **15**(3): 994–1000.
- Civanlar, S., Grainger, J. J., Yin, H. e Lee, S. S. H. (1988). Distribution feeder reconfiguration for loss reduction, *IEEE Transactions on Power Delivery* **3**(3): 1217–1223.
- Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization, *Erciyes University, Computer Engineering Department. Kayseri - Turkiye*.
- Kouba, N. E. Y., Mena, M., Hasni, M. e Boudour, M. (2015). Optimal load frequency control based on artificial bee colony optimization applied to single, two and multi-area interconnected power systems, *2015 3rd International Conference on Control, Engineering Information Technology (CEIT)*, pp. 1–6.
- Linh, N. T. e Anh, N. Q. (2010). Application artificial bee colony algorithm (abc) for reconfiguring distribution network, *2010 Second International Conference on Computer Modeling and Simulation*, Vol. 1, pp. 102–106.
- Nara, K., Shiose, A., Kitagawa, M. e Ishihara, T. (1992). Implementation of genetic algorithm for distribution systems loss minimum re-configuration, *IEEE Transactions on Power Systems* **7**(3): 1044–1051.
- Ravibabu, P., Venkatesh, K. e Kumar, C. S. (2008). Implementation of genetic algorithm for optimal network reconfiguration in distribution systems for load balancing, *2008 IEEE Region 8 International Conference on Computational Technologies in Electrical and Electronics Engineering*, pp. 124–128.
- Zhu, J., Chow, M.-Y. e Zhang, F. (1998). Phase balancing using mixed-integer programming [distribution feeders], *IEEE Transactions on Power Systems* **13**(4): 1487–1492.