

METAHEURÍSTICA INSPIRADA NA ECOLOCALIZAÇÃO DE MORCEGOS: APERFEIÇOAMENTO e ESTUDO DE CASOS

Francisco Carlos Rodrigues Coelho

Universidade Federal de Juiz de Fora – UFJF
Campus da UFJF, Plataforma do Setor de Tecnologia, 36036-330, Juiz de Fora, MG.
franciscorodriguescoelho@gmail.com

Ivo Chaves da Silva Junior

Universidade Federal de Juiz de Fora - UFJF
Campus da UFJF, Plataforma do Setor de Tecnologia, 36036-330, Juiz de Fora, MG.
ivo.junior@ufjf.edu.br

Bruno Henriques Dias

Universidade Federal Fluminense - UFF
Rua Passo da Pátria, 156, 422-D – 24210-240, São Domingos, Niterói, RJ.
bdias@ieee.org

André L. M. Marcato

Universidade Federal de Juiz de Fora - UFJF
Campus da UFJF, Plataforma do Setor de Tecnologia, 36036-330, Juiz de Fora, MG.
andre.marcato@ufjf.edu.br

RESUMO

O presente artigo tem por objetivo propor um aperfeiçoamento no processo de busca, em problemas complexos de otimização, baseado na ecolocalização de morcegos. Para tanto, fez-se uma modificação no algoritmo inicialmente proposto por Xin-She Yang. O algoritmo proposto faz uso de um processo adicional de seleção dos piores indivíduos durante cada iteração do processo de busca e dá a estes, a possibilidade de se deslocarem para novas posições. Este procedimento permite uma distribuição mais abrangente de indivíduos por toda a região de solução, fazendo com que a probabilidade de sucesso seja maior. Testes foram realizados na minimização de oito funções não convexas, de grande complexidade, e os resultados mostram que o aperfeiçoamento proposto aumenta a eficiência do processo de busca baseado na ecolocalização de morcegos.

ABSTRACT

The present paper proposes an improvement in the search process of the echolocation of bats algorithm applied to complex optimization problems. In order to do so it modifies the algorithm originally proposed by Xin-She Yang. In that way, the proposed algorithm uses an additional process to select the worst individuals in each iterative search process, given them the possibility to move to new search regions. This procedure allows a wider distribution of individuals throughout the search space, increasing the possibility of success. Tests were realized in the minimization of eight highly complex non-convex functions. The results show that the proposed improvement increases the search efficiency of the echolocation of bats algorithm.

KEYWORDS. Metaheuristics, Echolocation of Bats, Non-Convex Functions.

1. Introdução

A ecolocalização é uma sofisticada capacidade biológica utilizada para determinar a distância e/ou posição de obstáculos e/ou animais em um ambiente através da emissão de ondas ultrassônicas e analisar o tempo gasto para que as ondas emitidas, reflitam no alvo e voltem à fonte sobre a forma de eco. Os Morcegos têm este sentido bem desenvolvido, pois são animais de hábitos noturnos e não possuem uma boa visão. Nos morcegos, os pulsos são emitidos pela boca e narinas. Com base no tempo que os ecos demoram a voltar os morcegos detectam presas e obstáculos em seu caminho. Muitas vezes essas presas são pequenos insetos que refletem as ondas emitidas pelos morcegos, então, o comprimento de onda deve ser da ordem milímetros, o que implica em altas frequências, na ordem de 20-215 kHz, vide Figura 1.




Figura 1- Ecolocalização.

Baseando-se nesta capacidade natural, foi desenvolvida a “ecolocalização artificial” com o advento do radar, sonar e dos aparelhos de ultrassonografia. Seguindo essa linha, recentemente, foi desenvolvido na universidade de Cambridge, Reino Unido, pelo pesquisador Xin-She Yang, uma técnica de otimização baseada no fenômeno da ecolocalização. O grande apelo para utilização desta técnica é a resolução de problemas com inúmeras soluções (mínimos ou máximos locais), região de solução não convexa, vide Figura 2. Esta característica leva grande parte dos algoritmos de otimização a convergirem em direção a ótimos locais, sendo estes altamente dependentes das condições iniciais. Problemas com estas características podem ser encontrados nas mais diversas áreas de conhecimento (Damodaram, R. and Valarmathi, M.L., 2012 e Kumaravel, G. and kumar, C., 2011).




Figura 2 - Vários Mínimos e Máximos.

Em (Xin-She Yang, 2010), o algoritmo baseado na ecolocalização de morcegos foi comparado com duas outras técnicas de otimização bioinspiradas (Algoritmos Genéticos e

Enxame de Partículas) e os resultados foram considerados promissores.

Diante do quadro descrito anteriormente, o presente artigo propõe um aperfeiçoamento no algoritmo proposto em (Xin-She Yang, 2010). Testes foram realizados na minimização de algumas funções não convexas, de grande complexidade, e os resultados mostram que o aperfeiçoamento proposto aumenta a eficiência do processo de busca baseado na ecolocalização de morcegos.

2. Algoritmo

O algoritmo possui um número fixo n de morcegos virtuais que se deslocam ao longo das iterações de índice t sobre a superfície da função objetivo em estudo. Cada morcego se localiza em uma posição \mathbf{x}_i ($i = 1, 2, 3, \dots, n$) que representa uma possível solução para a função matemática que se deseja encontrar o ponto ótimo, sendo \mathbf{x}_* a melhor posição/solução na iteração t .

Inicialmente é necessário estabelecer algumas premissas em relação às características do processo referente à ecolocalização utilizado por morcegos, sendo estas:

- (i) Todos os morcegos fazem uso da ecolocalização para medir distância, e também a diferença entre sua presa e os limites do espaço onde ele se encontra;
- (ii) Os morcegos se deslocam para a posição \mathbf{x}_i no espaço através dos seguintes parâmetros: (a) velocidade \mathbf{v}_i ; (b) frequência f_i ; (c) volume do pulso emitido A_i ; (d) taxa de emissão de pulso r_i .

A Figura 3 apresenta o fluxograma básico do algoritmo baseado na ecolocalização de morcegos, com N significando o número máximo de iterações do algoritmo.

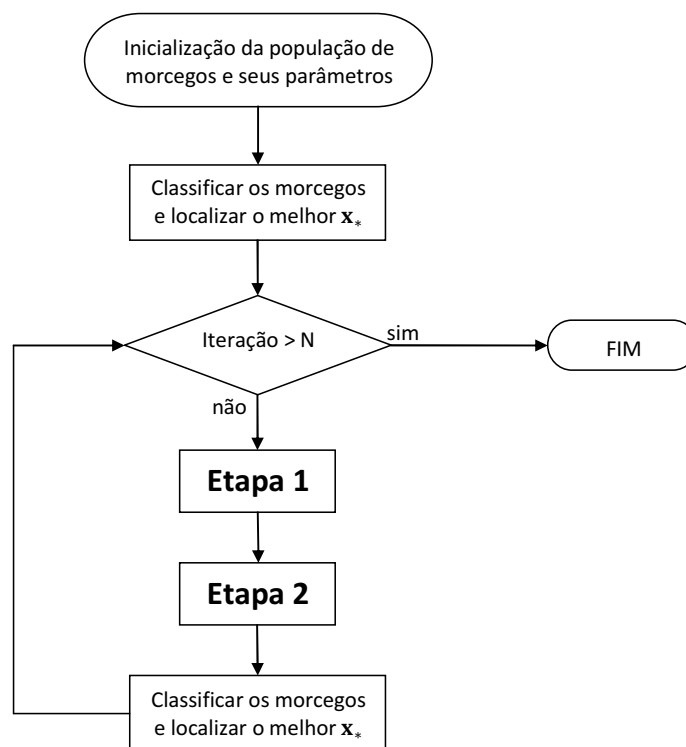


Figura 3 - Fluxograma Básico do Algoritmo.

Inicialmente gera-se uma população de morcegos, soluções iniciais, para o problema em análise, onde cada morcego tem sua própria taxa de emissão (r_i) e volume de pulso (A_i). Estas soluções são geradas de forma aleatória, porém dentro de limites previamente conhecidos. Com as soluções iniciais conhecidas, as mesmas são classificadas através do valor da função objetivo do problema em estudo. A seguir, entra-se no processo de busca, sendo a primeira etapa, bloco 1, apresentada no fluxograma abaixo, Figura 4.

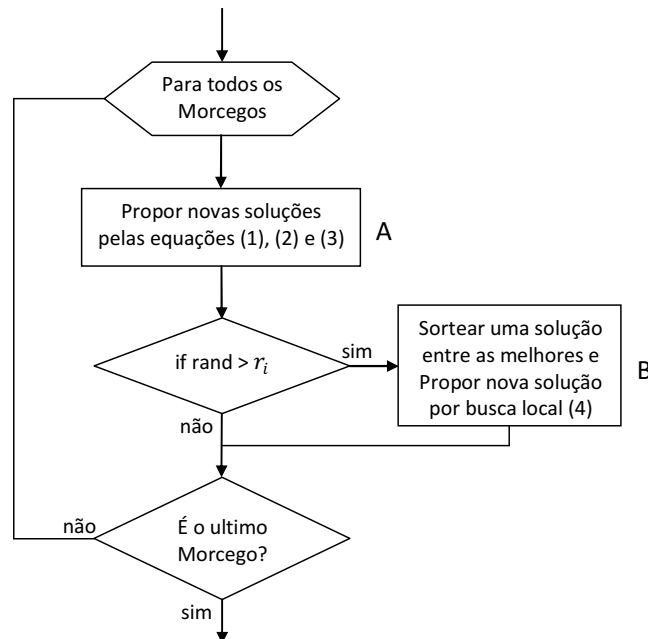


Figura 4 - Fluxograma - Etapa 1.

A frequência de cada morcego, a cada iteração, está compreendida entre f_{min} e f_{max} , sendo que $\beta \in [0,1]$ é um escalar aleatório proveniente de uma distribuição normal. A nova frequência, velocidade e posição no espaço são atualizadas de acordo com as seguintes equações:

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (1)$$

$$\mathbf{v}_i^t = \mathbf{v}_i^{t-1} + (\mathbf{x}_* - \mathbf{x}_i^{t-1})f_i \quad (2)$$

$$\mathbf{x}_i^t = \mathbf{x}_i^{t-1} + \mathbf{v}_i^t \quad (3)$$

Após a atualização dos parâmetros frequência, velocidade e posição, devem-se verificar as taxas de emissão de pulso emitidas por cada morcego. Essa verificação é feita comparando a taxa de emissão r_i com um ruído aleatório, função randômica (rand). Caso o ruído aleatório seja maior do que a taxa de emissão do pulso (r_i), significa que provavelmente o morcego-i (solução-i) está distante de sua presa (melhor solução). Assim sendo, executa-se uma busca local. Ou seja, sorteia-se uma solução entre as melhores e através de um pequeno deslocamento gera-se uma nova solução para o morcego-i, isto é:

$$\mathbf{x}_{novo} = \mathbf{x}_{velho} + \epsilon A^t \quad (4)$$

Onde $\epsilon \in [-1,1]$ é um escalar aleatório e A^t é a média dos volumes de todos morcegos na iteração t .

Com as novas soluções obtidas, bloco 1, parte-se para a segunda etapa, Figura 5. Inicialmente, verifica-se a ocorrência ou não de violações nos limites das novas soluções obtidas. Caso existam, estas são corrigidas, sendo as mesmas colocadas novamente dentro de seus limites superiores ou inferiores. A seguir duas condições devem ser analisadas: (i) verificar se a nova solução é melhor do que a solução anterior; (ii) comparar o volume do pulso com uma função randômica (rand). Caso o volume randômico seja menor do que o volume do pulso (A_i) significa que, provavelmente, o morcego-i (solução-i) está perto de sua presa (melhor solução). Caso estas duas condições sejam verdadeiras, aceitam-se as novas soluções e são atualizadas as taxas de emissão e volumes.

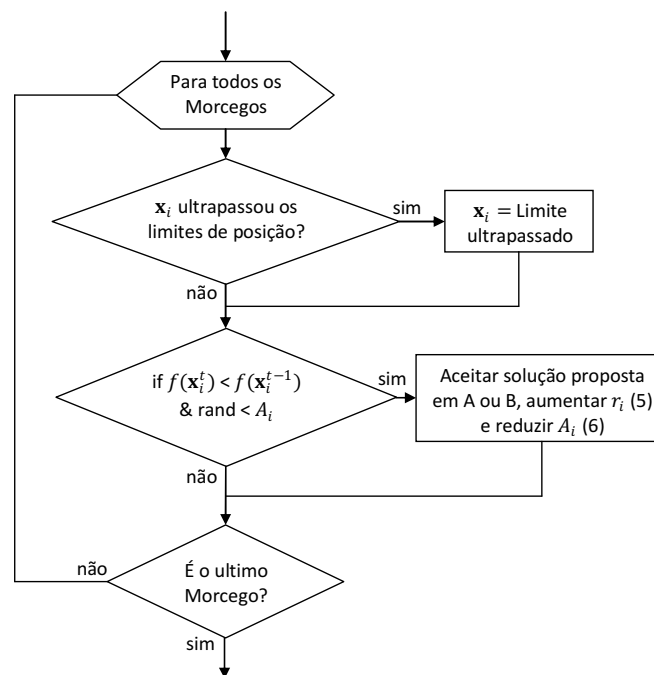


Figura 5 - Fluxograma - Etapa 2.

As taxas de emissão (r_i) e os volumes dos pulsos (A_i) são atualizados no decorrer do processo iterativo. Conforme o morcego se aproxima de sua presa, há um aumento da taxa de emissão de pulso e uma redução do volume do pulso emitido, sendo dadas pelas equações:

$$r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)], \quad (5)$$

$$A_i^{t+1} = \alpha A_i^t, \quad (6)$$

Onde α e γ são constantes positivas pertencentes aos intervalos $0 < \alpha < 1$ e $\gamma > 1$. Deste modo $A_i \rightarrow 0$ e $r_i \rightarrow r_i^0$ em $t \rightarrow \infty$.

Diante das descrições do algoritmo básico, o presente artigo propõe uma etapa adicional, após a verificação da ocorrência ou não de violações das novas soluções, vide Figura 6.

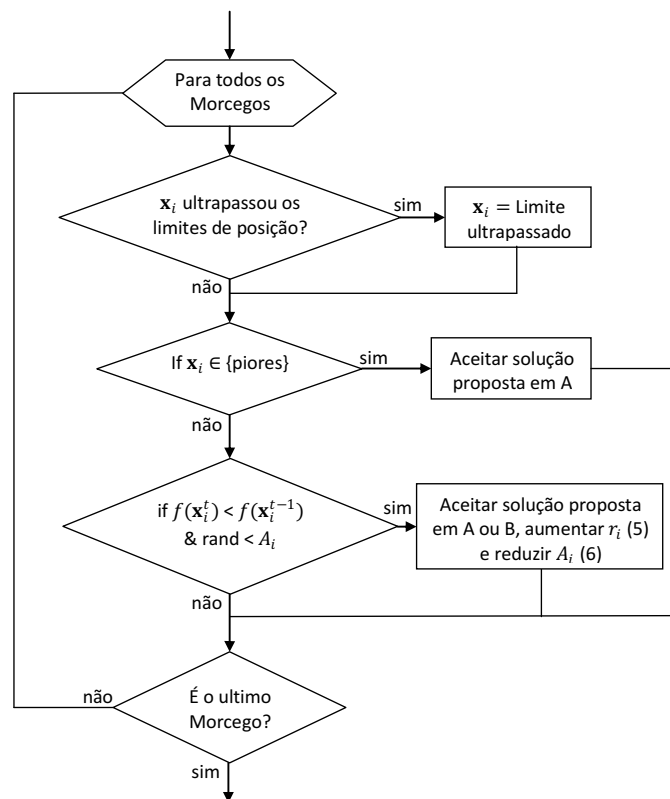


Figura 6 - Fluxograma - Etapa 2 Modificada.

Esta nova etapa consiste na elaboração de um conjunto de soluções contendo os piores indivíduos (morcegos) durante cada iteração do processo de busca. Desta forma, é dada a um percentual dos piores indivíduos a possibilidade de se deslocarem aleatoriamente para novas posições, independente da posição que se encontravam e dos volumes dos pulsos emitidos. Através desse procedimento pôde-se observar uma distribuição mais abrangente de indivíduos por toda a região de solução, fazendo com que a eficiência do processo de busca seja maior.

3. Estudo de Casos

O algoritmo proposto e inspirado na ecolocalização de morcegos será empregado e comparado com o algoritmo básico na minimização de oito funções matemáticas que apresentam alta complexidade para uma vasta lista de técnicas de otimização, porém duas destas funções serão apresentadas em detalhes: (a) *Eggcrate Function*, vide Figura 7; (b) *Rosenbrock Function*, vide Figura 8.

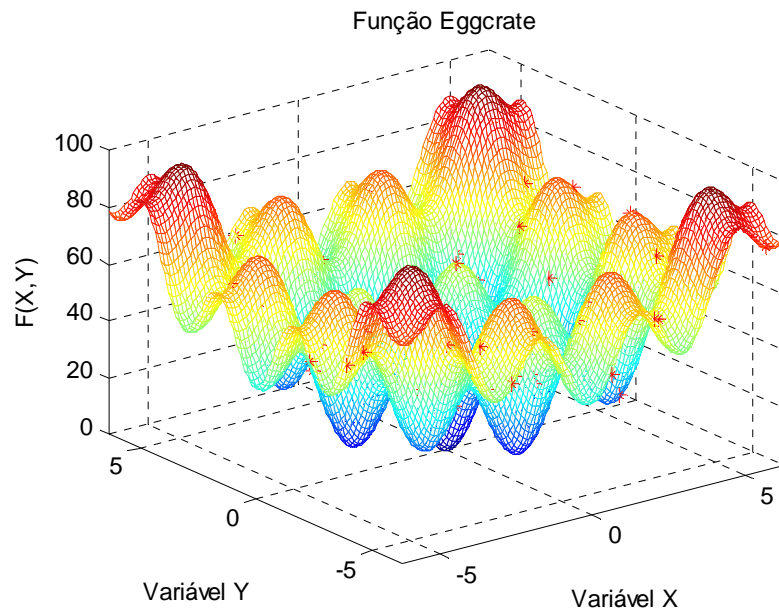


Figura 7 - *Eggcrate Function* - $F(x,y) = x^2+y^2+25x(\sin^2x + \sin^2y)$.

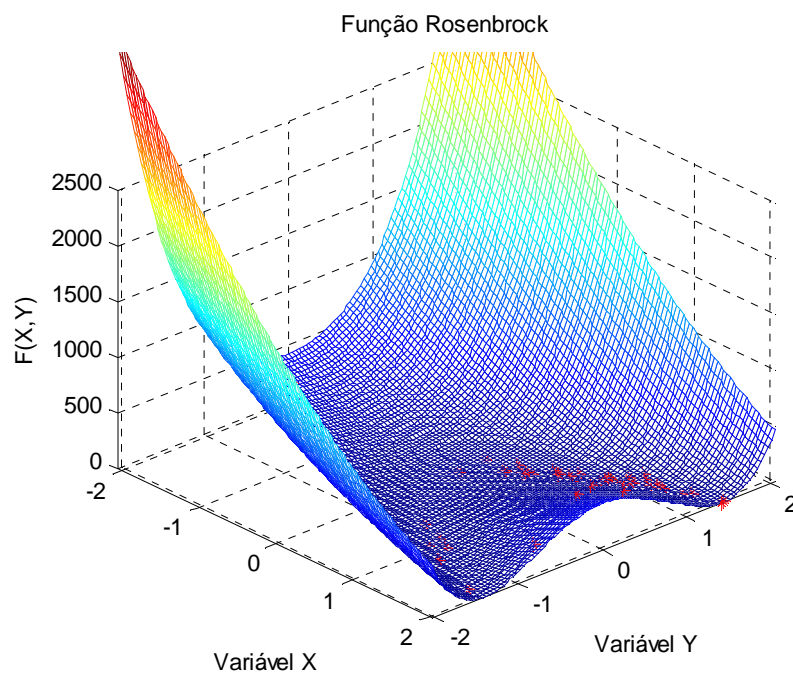


Figura 8 - *Rosenbrock Function* - $F(x,y) = (1-x)^2+100x(y-x^2)^2$.

Para analisar qualitativamente a modificação proposta no algoritmo básico fizeram-se as seguintes considerações: (i) Variou-se o percentual de piores morcegos, com o objetivo de verificar a influência da etapa adicional na solução da função “*Rosenbrock*”; (ii) Foram realizadas cem simulações do algoritmo de otimização. Como se trata de um algoritmo de otimização baseado em uma busca inteligente, as condições iniciais interferem na obtenção da solução final. Desta forma, uma análise mais coerente é avaliar a média das soluções obtidas; (iii) Foram utilizados cinquenta morcegos e um número máximo de sessenta iterações, sendo este último o

critério de convergência. A Figura 9 apresenta o valor da função “*Rosenbrock*” para as cem simulações do algoritmo básico proposto por Xin-She Yang. Destaca-se que foram utilizados sempre os mesmos pontos iniciais para o processo de busca.

Sabe-se que o ponto de mínimo da função *Rosenbrock* corresponde as coordenadas $x=1$ e $y=1$, sendo nulo o valor mínimo da função. Assim sendo, foram realizadas cem simulações do Algoritmo Básico (AB) e do Algoritmo Proposto (AP). As Figuras 9 e 10 apresentam os resultados obtidos de $F(x,y)$ para as cem simulações do AB e AP, respectivamente.

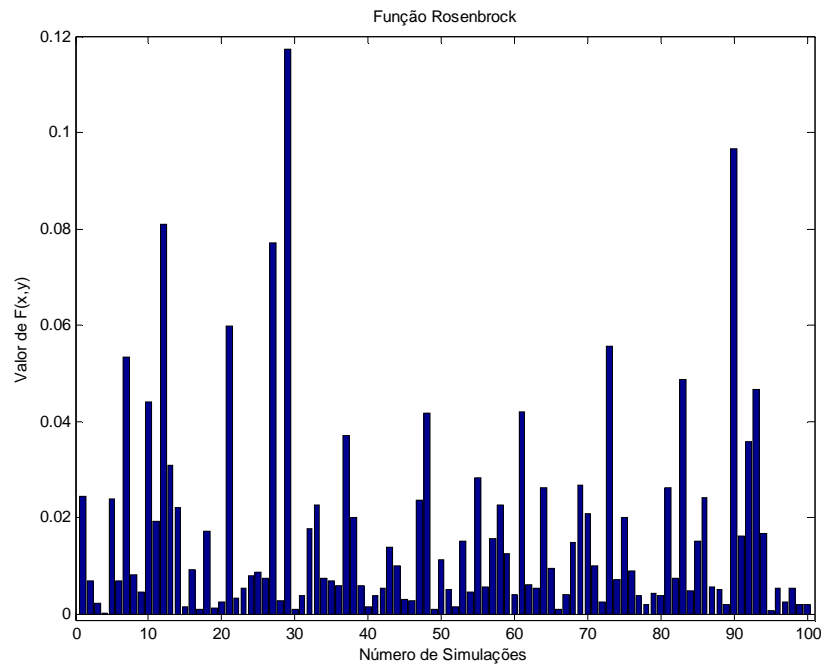


Figura 9 - *Rosenbrock Function* - 100 Simulações - Algoritmo Básico (AB).

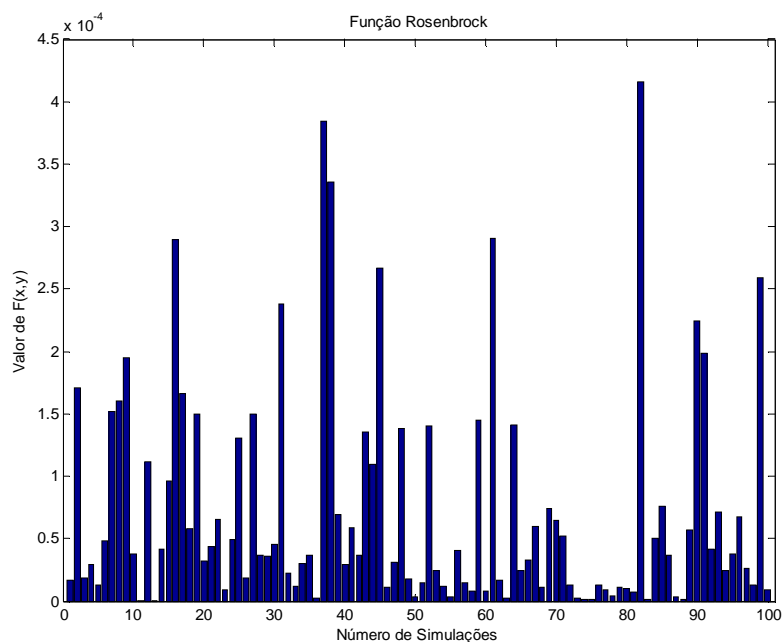


Figura 10 - *Rosenbrock Function* - 100 Simulações - AP (60%).

Destaca-se que para aferir a modificação feita no algoritmo básico, foram realizadas variações percentuais do conjunto composto pelas piores soluções. Este novo conjunto, a cada iteração do Algoritmo Proposto (AP), terá suas soluções sempre aceitas, porém sem que haja incremento da taxa de emissão de pulso e o decremento do volume do pulso. Desta forma, é permitido a estas soluções caminharem através da região de solução independente de sua posição anterior, taxa e volume de emissão de pulsos. Desta forma, espera-se melhorar a eficiência do processo de busca bioinspirado.

Diante do quadro descrito acima, foram realizadas variações percentuais do conjunto proposto dentro do intervalo [10% - 100%] com discretizações de 10%, sendo os melhores resultados encontrados em conjuntos compostos por 50%-70%. Para percentuais acima de 70%, o processo de busca torna-se muito aleatório.

A Tabela 1 apresenta uma comparação estatística entre a solução inicial gerada, a solução final obtida pelo algoritmo básico, à solução final obtida pelo algoritmo proposto com um conjunto de 60% e 80% para a função de Rosenbrock.

Tabela 1 – Dados Estatísticos – 100 Simulações da Função de Rosenbrock.

F(x,y)	Solução Inicial	Soluções Finais AB	Soluções Finais AP (60%)	Soluções Finais AP (80%)
Mínimo	1	0.0002043	4.749e-008	0.000589
Maximo	100	0.1173	0.0004163	3.148
Média	50.5	0.01656	7.217e-005	0.3171
Mediana	50.5	0.007373	3.715e-005	0.1969
Desvio Padrão	29.1	0.02104	8.952e-005	0.4244

Diante dos resultados apresentados é possível verificar que a modificação proposta resultou em um aumento da eficiência do processo de busca, uma vez que todos os parâmetros estatísticos foram reduzidos com a mudança proposta, com exceção para um conjunto de 80% das piores soluções. Neste cenário pode-se verificar, principalmente, a média das simulações e o desvio padrão tornam-se altos. Ou seja, as soluções tendem a se afastar do ponto de mínimo global, nulo.

Com o objetivo de ilustrar a evolução do processo de busca, a Figura 11 apresenta respectivamente os pontos de partida (à esquerda) e chegada (à direita) do algoritmo proposto para a função *Rosenbrock*, onde cada ponto em vermelho corresponde à localização de um morcego, solução potencial, e o ponto verde a localização do melhor morcego. Verifica-se ainda na imagem à direita, que na convergência do processo há uma maior concentração de morcegos virtuais próxima ao ótimo global da função.

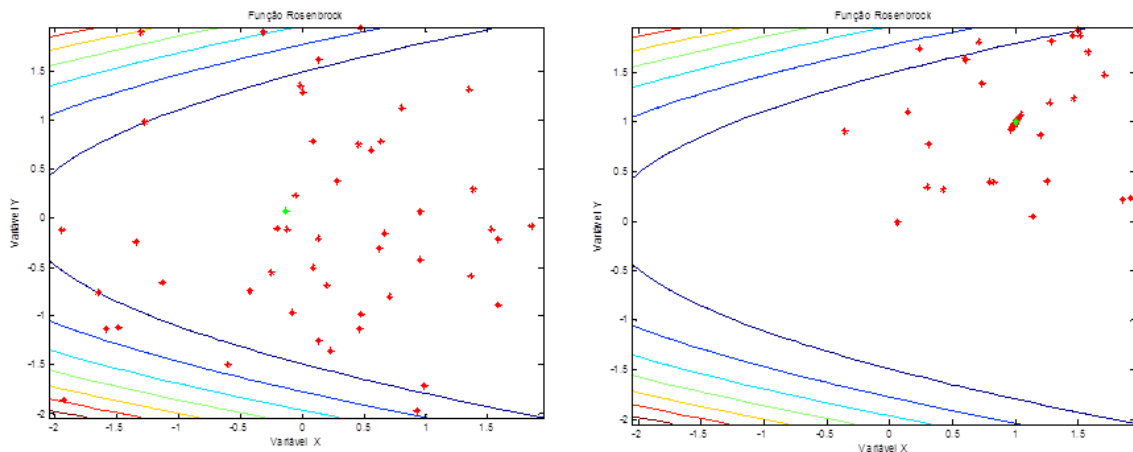


Figura 11- *Rosenbrock Function* - Soluções Iniciais e Finais - AP(60%).

Para analisar qualitativamente a modificação proposta no algoritmo básico fizeram-se as mesmas considerações para função *Eggcrate*: (i) Variou-se o percentual de piores morcegos, com o objetivo de verificar a influência da etapa adicional na solução; (ii) Foram realizadas cem simulações do algoritmo de otimização. (iii) Foram utilizados cinquenta morcegos e um número máximo de sessenta iterações, sendo este último o critério de convergência.

A Figura 12 apresenta a comparação entre os valores da função *Eggcrate* para as cem simulações do Algoritmo Básico (AB) por Xin-She Yang e do Algoritmo Proposto (AP), para um conjunto de 60% das piores soluções.

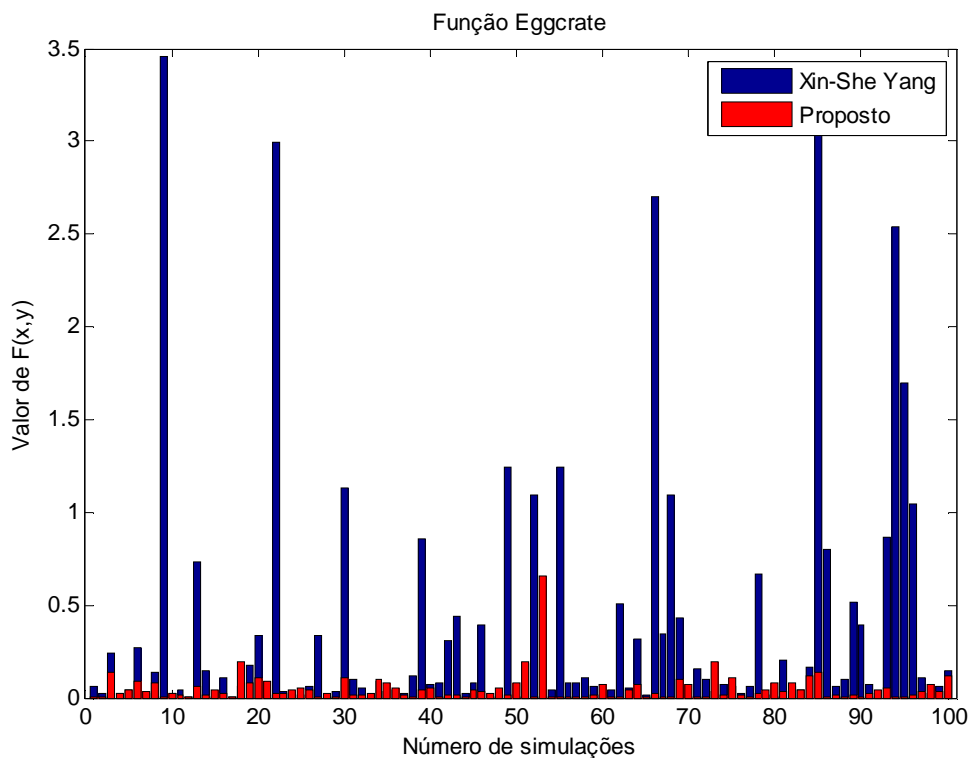


Figura 12 - *Eggcrate Function* - 100 Simulações – Comparação ABxAP.

O ponto de mínimo da função *Eggcrate* corresponde às coordenadas $x=0$ e $y=0$, sendo nulo o valor da função. Desta forma, através da Figura 15 pode-se constatar o aumento da eficiência do algoritmo com a modificação proposta, uma vez que a média das soluções obtidas pelo algoritmo proposto é bem inferior à média obtida pelo algoritmo básico. Os dados estatísticos relativos às simulações dessa função objetivo podem ser observados na Tabela 2.

Tabela 2 - Dados Estatísticos - 100 Simulações da Função *Eggcrate*.

F(x,y)	Solução Inicial	Soluções Finais AB	Soluções Finais AP (60%)
Mínimo	17.6881	5.0854e-004	8.0352e-005
Maximo	91.8545	3.4558	0.6599
Média	51.8688	0.3635	0.0475
Mediana	50.3171	0.0735	0.0257
Desvio Padrão	15.0896	0.6999	0.0761

Diante da Tabela 2 nota-se a melhora que a alteração proposta no algoritmo proporciona ao processo de busca do problema de otimização, pois a média das soluções é mais baixa na coluna AP (60%) e o mesmo ocorre para o desvio padrão, o que significa que as soluções são melhores (menores) e mais uniformes.

Com o objetivo de aferir melhor a modificação proposta foram realizadas novas simulações com outras seis funções de alta complexidade (Xin-She Yang, 2010). A Tabela 3 fornece os valores de Média (M), Desvio Padrão (DP) e o Percentual de vezes que a solução Ótima Global foi encontrada (POG) para cada uma das novas funções em estudo. Cada função foi simulada cem vezes utilizando-se o Algoritmo Básico (AB) e o Algoritmo Proposto (AP). Em todas as simulações o objetivo é a minimização das funções em análise.

Tabela 3 - Dados Estatísticos - Outras Funções.

Funções	Soluções Finais - AB			Soluções Finais - AP (60%)		
	M	DP	POG	M	DP	POG
Michalewicz	-1.8583	0.0333	64%	-1.8738	0.0196	86%
De Jong	4.131e-004	5.094e-004	100%	3.097e-004	3.959e-004	100%
Schwefel	-767.6616	64.1532	53%	-827.6952	28.4358	93%
Ackley	1.4362	1.0717	71%	0.2468	0.2991	100%
Easom	-0.8127	0.2010	34%	-0.9924	0.0192	93%
Griewangk	0.0079	0.0064	34%	0.0047	0.0038	60%

Pela Tabela 3 é possível verificar, novamente, uma maior eficiência no processo de busca com o algoritmo proposto, uma vez que a alteração no algoritmo básico proporcionou um percentual maior de acertos. Ou seja, a solução ótima foi obtida com maior frequência.

4. Conclusões

Este artigo apresentou os principais conceitos do processo de otimização baseado na ecolocalização de morcegos. Foi apresentado o algoritmo básico e uma etapa adicional foi proposta a este algoritmo. Esta nova etapa consiste na elaboração de um conjunto de soluções

contendo um percentual dos piores indivíduos (morcegos) durante cada iteração do processo de busca. Desta forma, é dada a este percentual a possibilidade de se deslocarem para novas posições (soluções), independente da posição que se encontravam, das taxas de emissão de pulsos e dos volumes dos pulsos emitidos. Assim, pode-se concluir:

- A etapa adicional proposta ao algoritmo básico, baseado na ecolocalização de morcegos, mostrou-se eficiente, sendo possível obter soluções de melhor qualidade com uma frequência maior.
- O percentual do conjunto de piores soluções é um parâmetro importante, pois valores percentuais altos podem tornar o processo de busca muito aleatório;
- A garantia de obtenção do ponto de mínimo global só pode ser obtida através da enumeração exaustiva, o que nem sempre é possível em diversos problemas reais devido ao elevado tempo de processamento;

Referências

- Altringham, J. D.**(1996) Bats: Biology and Behaviour, Oxford University Press.
- Damodaram, R. and Valarmathi, M.L.** (2012) Phishing website detection and optimization using Modified bat algorithm.
- Goldberg, D.**(1989) Genetic Algorithms in Search, Optimization and Machine Learning Addison-Wesley, Reading, MA.
- Kennedy, J. and Eberhart, R.** (2001) Swarm Intelligence. Academic Press.
- Kumaravel, G. and kumar, C.** (2011) Design of Self-Tuning PI Controller for STATCOM using Bats Echolocation Algorithm.
- Yang, X.-S.**(2008) Nature-inspired Metaheuristic Algorithms. Luniver Press.
- Yang, X.-S.** A (2010) New Metaheuristic Bat-Inspired Algorithm, in: Nature Inspired Cooperative Strategies for Optimization, Studies in Computational Intelligence, Springer Berlin, 284, Springer, 65-74.