

Aperfeiçoamento do BAT: Inserção de Novas Etapas e Análise de Desempenho

Allan Vilar de Carvalho*

Wellington Candeia de Araujo**

Lucas Vale F. da Silva***

Resumo

Este artigo propõe para o algoritmo de morcego, que possui eficiência e aplicações nas mais diversas áreas, a inserção de novas etapas, tendo como objetivo principal o aperfeiçoamento do mesmo. Foi acrescentada a possibilidade de as novas soluções não aceitas serem atualizadas uma única vez pelo mesmo morcego, realizando apenas na melhor solução temporária testes que verificam a sua qualidade perante as outras, ocasionado as atualizações. Testes foram realizados em 2 funções unimodais e 3 funções multimodais de alta complexidade e referenciadas, que comprovaram melhorias significativas tanto no processo de busca como no processamento dos dados, ficando evidente a origem de um novo algoritmo de morcego.

Palavras Chaves: BAT. Microchiroptera. Algoritmo evolutivo. Ecolocalização. Otimização global.

* Graduando em Bacharelado em Ciência da Computação pela Universidade Estadual da Paraíba - Patos.
E-mail: allan_taperoapb@hotmail.com.

** Professor doutor na Universidade Estadual da Paraíba - Patos. E-mail: wcandeia@uepb.edu.br.

*** Graduando em Bacharelado em Ciência da Computação pela Universidade Estadual da Paraíba - Patos.
E-mail: valelucas1@gmail.com.

1 Introdução

Atualmente certas classes de problemas são melhor resolvidas, com algoritmos evolutivos, muitas possuem diversas vantagens, como exemplo: simplicidade e flexibilidade (XIE, ZHOU, CHEN, 2013; YANG, 2014). O BAT desenvolvido por Xin-She Yang (2010) é um exemplo de algoritmo evolutivo, que foi desenvolvido a partir da habilidade de ecolocalização dos morcegos, especificamente a espécie *Microchiroptera* utiliza-se de uma forma mais extensa essa aptidão, podendo diferenciar na escuridão diversos tipos de insetos.

Após a criação do BAT, e constatada a sua eficiência, várias aplicações em diversas áreas surgiram, como exemplo: processamento de imagens, mineração de dados e área de otimização, foram desenvolvidas, ficando evidente a sua flexibilidade (YANG, 2014).

O BAT básico, tem várias vantagens em relação aos métodos de otimização global tradicional, mas a taxa de convergência lenta e a baixa precisão ainda existe (XIE, ZHOU, CHEN, 2013). Diante disso, esse artigo apresenta o BAT modificado, com novas etapas que foram implantadas com o objetivo de melhorar o processo de busca.

Este artigo é formado por 4 seções, além desta introdução e da conclusão. Na primeira relata-se um aparato de informações sobre a ecolocalização de morcegos. Na segunda seção, apresentam-se informações do BAT, constando abstrações utilizadas para sua criação. Na terceira inclui-se a exposição das novas etapas. Na quarta seção são discutidos os experimentos realizados, com o objetivo de comprovar as melhorias ocasionadas no BAT.

2 Ecolocalização dos Morcegos

Os únicos mamíferos com asas são os morcegos, esses animais tem uma extraordinária aptidão chamada de ecolocalização, onde faz com que se localize em um determinado espaço (YANG, 2010). Atualmente estima-se que existe cerca de 996 espécies de morcego, onde representam cerca de 20% de todas as espécies de mamíferos; seu tamanho varia entre o minúsculo morcego abelha com peso de 2 g para o enorme morcego megaquiróptero com cerca de 2 Kg (YANG, 2010). A maioria dos morcegos possui a habilidade de ecolocalização bem desenvolvida, pelo fato de serem animais de hábitos noturnos e possuir uma péssima visão.

A *Microchiroptera*, é um tipo de espécie de morcego que utiliza a habilidade de ecolocalização mais extensivamente, podendo emitir um eco muito superior à o eco emitido por outras espécies de morcego. Esse tipo de morcego emite um eco

muito alto e curto, que percorre por volta dos objetos e é recebido por suas orelhas, onde consegue localizar o local ao qual o objeto está situado, e mais, consegue distinguir presa e obstáculos e com essa distinção evita-se colisões em obstáculos (XIE, ZHOU, CHEN, 2013).

Normalmente os morcegos emitem pulso de som que duram em torno de 8 a 10 milésimos de segundo, que está entre 25 kHz a 150 kHz de frequência; já a espécie *Microchiroptera* emite cerca de 10 a 20 pulsos de som a cada segundo, podendo chegar a 200 pulsos quando estão perto das presas.

Segundo estudos, a *Microchiroptera*, usa o tempo de atraso da emissão e detecção do eco, a diferença de tempo entre as suas duas orelhas, e as variações de intensidade dos ecos, para construir um cenário tridimensional (YANG, 2010). Diante do exposto, foi desenvolvido o BAT, detalhado na próxima sessão.

3 BAT

Com base nas características dos morcegos, tem-se as abstrações a seguir, com base para a criação do algoritmo:

- Todos os morcegos utilizam a ecolocalização para medir distância, e conseguir diferenciar a caça e obstáculos;
- Os morcegos se movimentam, com velocidade v_i na posição x_i com uma frequência fixa f_{min} ;
- Para os morcegos localizarem presas, ocorre a alteração da frequência f_i e do volume sonoro A_0 ;
- A frequência dos impulsos emitidos e a taxa de emissão de pulso r_i podem ser ajustadas de acordo com a proximidade no alvo.

A frequência fixa f_i do morcego x_i é definida a partir do intervalo $[f_{min}, f_{max}]$, onde corresponde a um comprimento de onda entre o intervalo $[\lambda_{min}, \lambda_{max}]$, devido ao fato que λ e f estão relacionados já que $\lambda f = V$. Com a velocidade do som no ar de $v = 340$ m/s, pode-se afirmar que uma frequência [20 kHz, a 500 kHz] corresponde a uma gama de comprimentos de onda [0,7 mm, a 17 mm]. Em toda frequência quanto mais alta, menor será o comprimento de onda, e viajará a uma distância menor, diferentemente de uma frequência baixa, onde terá um comprimento de onda maior e viajará a uma distância maior (XIE, 2013; YANG, 2010).

A Figura 1 apresenta o fluxograma simplificado do algoritmo BAT, composto pelas principais fases e com N representando a quantidade de iterações.

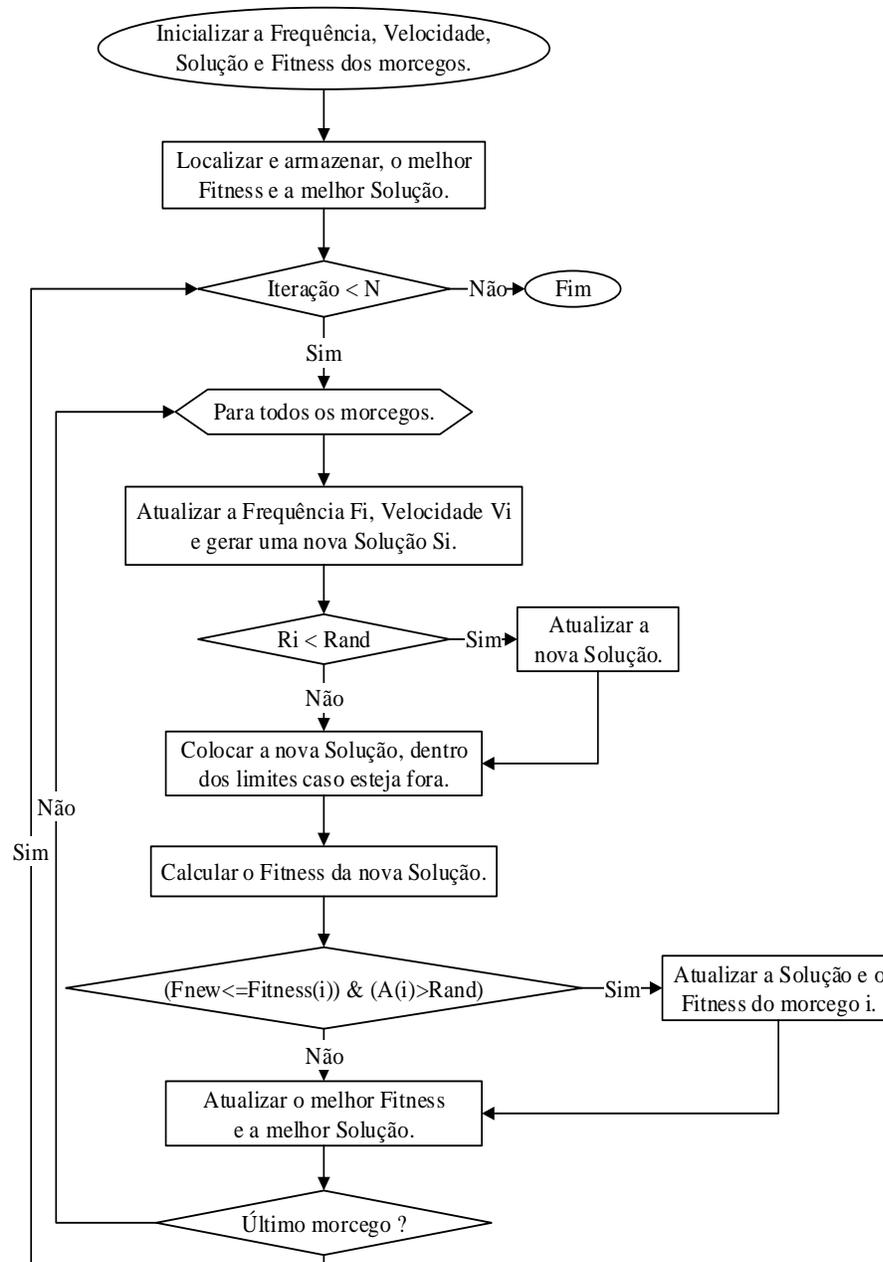


Figura 1 - Fluxograma do BAT.
Fonte: Elaborado pelos autores.

Inicializa-se a frequência, velocidade, solução e *fitness* dos morcegos para obter a localização e armazenamento da melhor solução. A cada iteração, cria-se uma nova solução, gerada a partir da atualização da frequência e velocidade e verifica-se em seguida a taxa de pulso, podendo ocasionar uma atualização. Posteriormente a nomeação do *fitness* e ao fim da iteração realiza-se a comprovação de qualidade da nova solução, necessária para ocorrer a atualização no morcego.

3.1 Movimentação

No decorrer das iterações, a frequência f_i e velocidade v_i são atualizadas, e gera-se uma nova solução (posição) x_i para o morcego $_i$, ocasionando-se a movimentação caso a nova solução esteja mais próxima da presa. As atualizações são realizadas pelas seguintes fórmulas:

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

$$v_i^{t+1} = v_i^t + (x_i^t - x_*)f_i, \quad (2)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1}, \quad (3)$$

Onde $\beta \in [0, 1]$ é um vetor aleatório e x_* é a melhor solução na iteração t , encontrada após ser realizada uma verificação entre todas as soluções (YANG, 2014).

Após a criação da nova solução é verificada a taxa de pulso r_i onde é comparada com um ruído aleatório. Caso a taxa de pulso seja menor, provavelmente a nova posição estará distante da solução ótima. Dessa maneira, atualiza-se a nova solução, com base na melhor solução, e na média dos volumes A^t de todos os morcegos na iteração t , utiliza-se a equação (4) a seguir (CARLOS et al., 2012):

$$x_{new} = x_{old} + \epsilon A^t, \quad (4)$$

Onde $\epsilon \in [-1,1]$ é um número aleatório (YANG, 2014).

São definidos limites inicialmente, onde os morcegos podem se movimentar, há a chance do morcego $_i$ sair desse limite, por isso é realizada uma inspeção em cada nova solução gerada, logo após a verificação da taxa de pulso, vista na seção 3.2 a seguir.

3.2 Volume e Taxa de Pulso

Todos os morcegos possuem, um volume $A_i \in [0,1]$ e uma taxa de pulso $r_i \in [0,1]$, onde serão atualizados no decorrer das iterações, caso as novas soluções sejam melhores (YANG, 2010). A atualização do r_i e do A_i ocorre utilizando as seguintes fórmulas:

$$A_i^{t+1} = \alpha A_i^t, \quad (5)$$

$$r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)], \quad (6)$$

Onde α e γ são valores constantes, que estão incluídos no intervalo $0 < \alpha < 1$ e $\gamma > 0$, normalmente usa-se $\alpha = \gamma = 0,9$ (YANG, 2010).

4 BAT – Contribuições com novas etapas.

Perante os resultados do BAT (YANG, 2010), o presente artigo propõe novas etapas mantendo a inspiração na ecolocalização de morcegos, implementadas para melhorar a taxa de convergência. A seguir, a Figura 2 expõe o fluxograma simplificado do BAT Modificado, com as novas etapas destacadas.

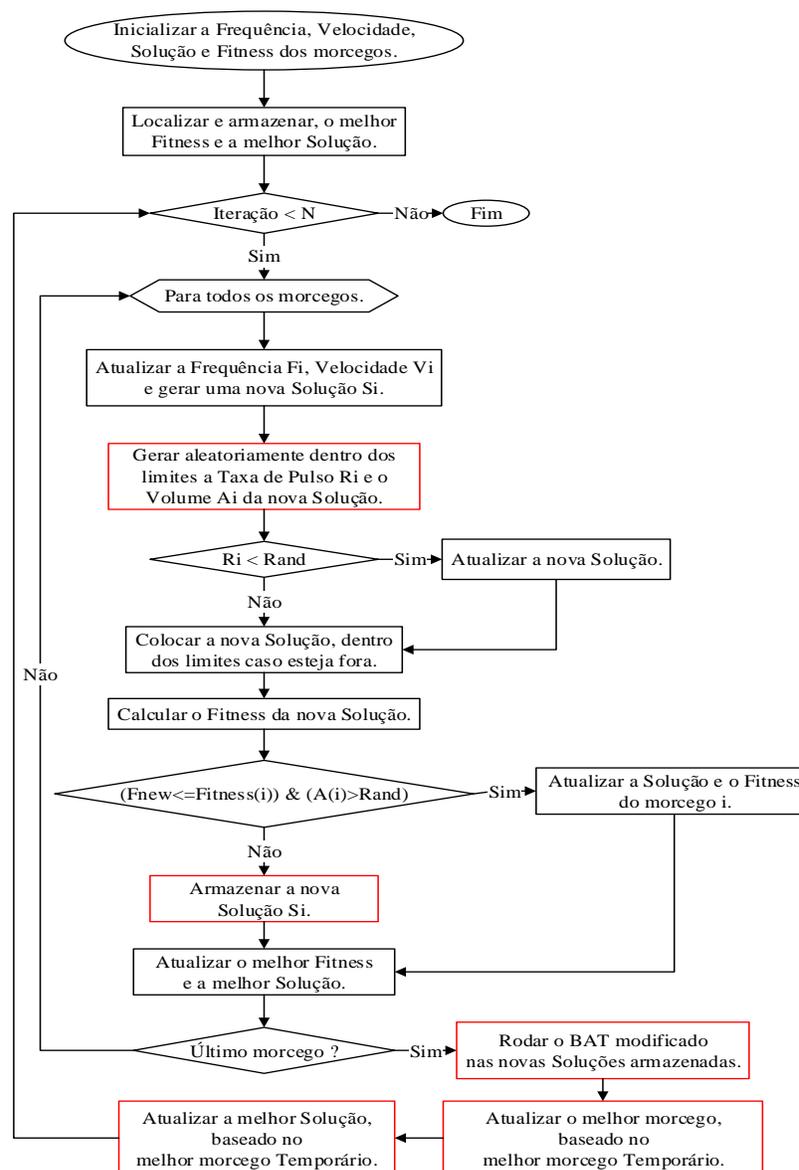


Figura 2 - Fluxograma do BAT Modificado.

Fonte: Elaborado pelos autores.

Fixou-se o intervalo de inicialização do volume das novas soluções em, $0.5 < A_i < 1$ para ocasionar volumes iniciais mais próximos de 1. Já o intervalo de inicialização da taxa de pulso das novas soluções em, $0 < r_i < 0.5$ para gerar taxas de pulso iniciais mais próximas de 0. Soluções não aceitas, são armazenadas produzindo um grupo de soluções temporárias a cada iteração, onde ao término da iteração i as novas soluções não aceitas são atualizadas apenas uma vez pelo mesmo BAT. Apenas a melhor solução temporária, tem a chance de atualizar o melhor morcego e a melhor solução na iteração i . Essa nova estrutura, com novas etapas e nova forma de inicialização do volume e da taxa de pulso, ocasionou melhores resultados que podem ser comprovados na seção 5.

5 Experimentos

Existem diversas funções de teste padrão, com alta complexidade, que são utilizadas para realizar validação de algoritmos. Serão apresentados os resultados dos testes feitos, com 2 funções unimodais e 3 funções multimodais de *benchmark*, que têm sido extensivamente utilizadas (JANSON, 2005). A seguir, Tabela 1 expondo as definições das funções.

Tabela 1 - Definições das funções *benchmark*.

Função	Fórmula
Griewank	$f(x) = \sum_{i=1}^d \frac{x_i^2}{4000} - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$
Rastrigin	$f(x) = 10d + \sum_{i=1}^d [x_i^2 - 10\cos(2\pi x_i)]$
Schwefel	$f(x) = 418.9829D - \sum_{i=1}^D x_i \sin\sqrt{ x_i }$
Sphere	$f(x) = \sum_{i=1}^d x_i^2$
Rosenbrock	$f(x) = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$

Fonte: Elaborado pelos autores.

Destaca-se que foram utilizados 50 morcegos, e realizadas 100 simulações em cada função para cada algoritmo, com 5000 iterações a cada simulação, sendo

este último o fator de convergência. A seguir, comparações dos resultados do BAT Modificado - BM com o BAT Básico - BB.

Griewank, é uma função multimodal, tendo vários mínimos locais generalizados e distribuídos regularmente, seu mínimo global $f(x^*)=0$ em $x^*=(0, \dots, 0)$ (SURJANOVIC, 2013), utilizou-se a dimensão $D=30$ e os limites $L=[-600,600]$ (YILMAZ, 2013). A seguir, Figura 3 expõe a comparação dos resultados.

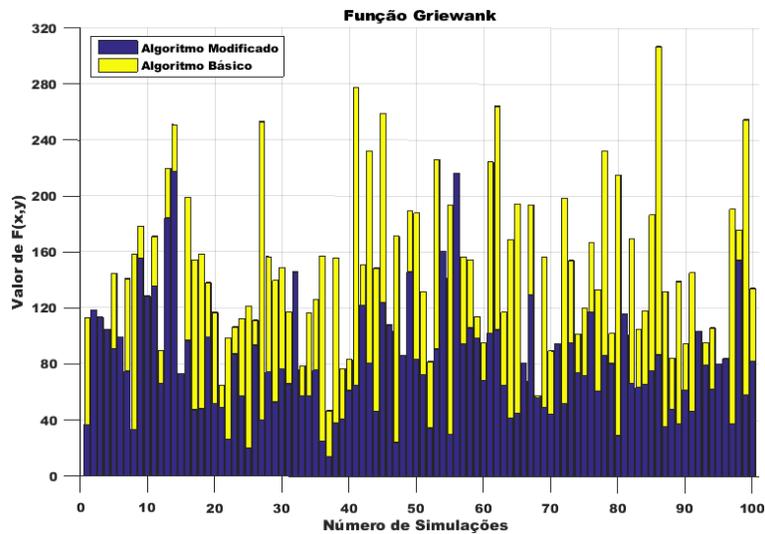


Figura 3 - Função Griewank - 100 Simulações – Comparação BMxBB.
Fonte: Elaborado pelos autores.

Tabela 2 - Dados Estatísticos - 100 Simulações da Função Griewank.

F (x, y)	Soluções Finais BB	Soluções Finais BM
Mínimo	46,5335	14,1304
Máximo	307,1171	217,6912
Média	141,2714	79,332
Mediana	133,9452	74,369
Desvio Padrão	55,9672	39,717

Fonte: Elaborado pelos autores.

Tabela 3 - Função de teste - 100 Simulações da Função Griewank.

Função de teste	BAT Básico	BAT Modificado
Média	250000	179698,74

Fonte: Elaborado pelos autores.

Perante os dados apresentados na Tabela 2, onde consta a comparação estatística das soluções finais dos algoritmos BAT's, e na Tabela 3 onde consta a quantidade média de vezes que a função de teste foi utilizada, observa-se uma diminuição numérica expressiva em todos os parâmetros, ficando evidente a melhora provocada pelas novas etapas implantadas ao BAT.

Rosenbrock, mais conhecida como função vale, tem o mínimo global $f(x^*)=0$ em $x^*=(1, \dots, 1)$ (SURJANOVIC, 2013), utilizou-se a dimensão $D=30$ e os limites $L=[-30,30]$ (FARAHANI et al., 2011). A seguir, a Figura 4 expõe a comparação dos resultados.

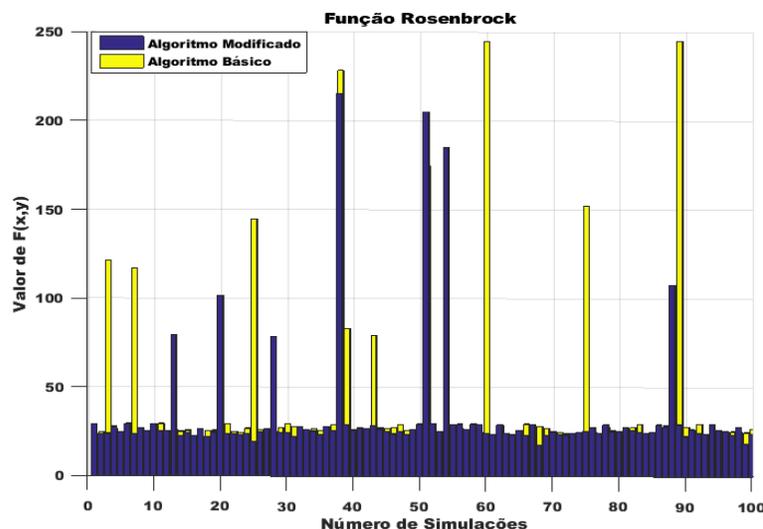


Figura 4 – Função Rosenbrock - 100 Simulações – Comparação BMxBB.
Fonte: Elaborado pelos autores.

Tabela 4 - Dados Estatísticos - 100 Simulações da Função Rosenbrock.

F (x, y)	Soluções Finais BB	Soluções Finais BM
Mínimo	21,0121	17,5428
Máximo	245,0931	215,683
Média	39,0477	33,5522
Mediana	25,6917	25,4656
Desvio Padrão	44,4585	32,7807

Fonte: Elaborado pelos autores.

Tabela 5 - Função de teste - 100 Simulações da Função Rosenbrock.

Função de teste	BAT Básico	BAT Modificado
Média	250000	237792,24

Fonte: Elaborado pelos autores.

Diante dos dados apresentados na Tabela 4, onde consta a comparação estatística das soluções finais dos algoritmos BAT's, nota-se que apenas a mediana não obteve uma diminuição significativa, já na Tabela 5 observa-se uma diminuição expressiva na quantidade média de vezes que a função de teste foi utilizada.

Sphere, é uma função unimodal, onde tem o mínimo global $f(x^*)=0$ em $x^*=(0, \dots, 0)$ (SURJANOVIC, 2013), utilizou-se a dimensão $D=30$ e os limites $L=[-100,100]$ (CHOU, 2016). A seguir, Figura 5 expõe a comparação da quantidade média de vezes que a função de teste foi utilizada.

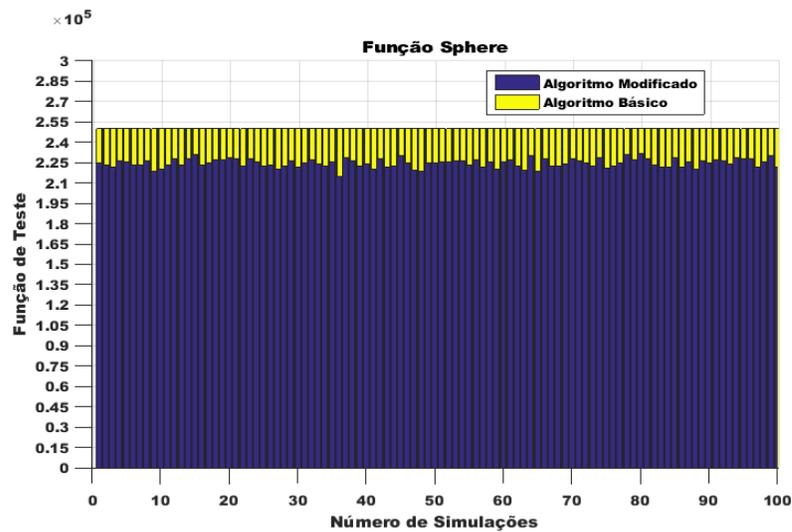


Figura 5 - Função Sphere - 100 Simulações – Comparação BMxBB.
Fonte: Elaborado pelos autores.

Tabela 6 - Dados Estatísticos - 100 Simulações da Função Sphere.

F (x, y)	Soluções Finais BB	Soluções Finais BM
Mínimo	0,00081463	0,00087791
Máximo	0,0013882	0,0014867
Média	0,0011501	0,0011796
Mediana	0,0011532	0,0011681
Desvio Padrão	0,00012836	0,00012447

Fonte: Elaborado pelos autores.

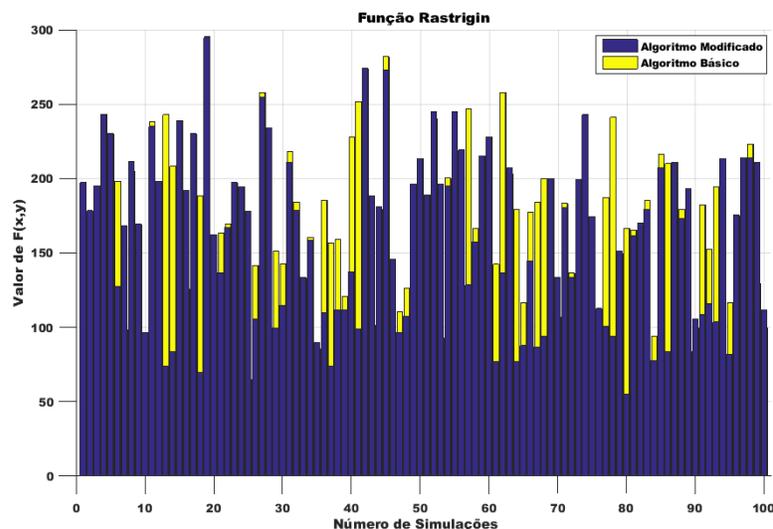
Tabela 7 - Função de teste - 100 Simulações da Função Sphere.

Função de teste	BAT Básico	BAT Modificado
Média	250000	224569,97

Fonte: Elaborado pelos autores.

Perante os dados apresentados na Tabela 6, nota-se que houve uma grande semelhança nos parâmetros, não ocasionando uma melhora significativa, mas na Tabela 7 verifica-se uma diminuição expressiva na quantidade média de vezes que a função de teste foi utilizada, dando uma diferença média de 25.430 mil vezes, ficando claro a diminuição do processamento de dados.

Rastrigin, é uma função multimodal, tendo vários mínimos locais distribuídos regularmente, seu mínimo global $f(x^*)=0$ em $x^*=(0, \dots, 0)$ (SURJANOVIC, 2013), utilizou-se a dimensão $D=30$ e os limites $L=[-5.12, 5.12]$ (FARAHANI et al., 2011). A seguir, Figura 6 expondo a comparação dos resultados.



Fonte: Elaborado pelos autores.

Tabela 8 - Dados Estatísticos - 100 Simulações da Função Rastrigin.

F (x, y)	Soluções Finais BB	Soluções Finais BM
Mínimo	64,8926	54,9339
Máximo	295,717	294,7196
Média	168,5087	161,873
Mediana	171,3321	169,8531
Desvio Padrão	52,7599	56,6959

Fonte: Elaborado pelos autores.

Tabela 9 - Função de teste - 100 Simulações da Função Rastrigin.

Função de teste	BAT Básico	BAT Modificado
Média	250000	248992,26

Fonte: Elaborado pelos autores.

Schwefel, é uma função multimodal muito complexa, seu mínimo global $f(x^*)=0$ em $x^*=(420.9687, \dots, 420.9687)$ (SURJANOVIC, 2013), utilizou-se a dimensão $D=30$ e os limites $L=[-500,500]$ (CHOU, 2016). A seguir, Figura 7 expõe a comparação dos resultados.

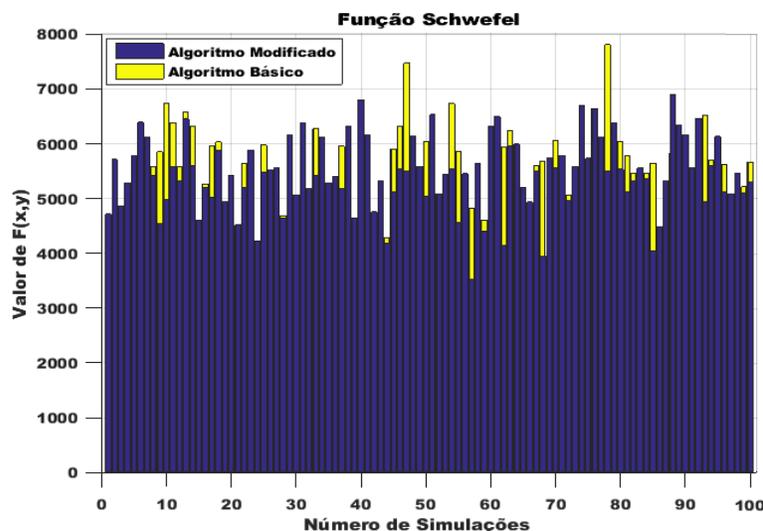


Figura 7 - Função Schwefel - 100 Simulações – Comparação BMxBB.

Fonte: Elaborado pelos autores.

Tabela 10 - Dados Estatísticos - 100 Simulações da Função Schwefel.

F (x, y)	Soluções Finais BB	Soluções Finais BM
Mínimo	3969,2837	3507,8413
Máximo	7810,4252	6890,5519
Média	5474,2977	5433,2902
Mediana	5461,6287	5449,4032
Desvio Padrão	702,3278	675,6358

Fonte: Elaborado pelos autores.

Tabela 11 - Função de teste - 100 Simulações da Função Schwefel.

Função de teste	BAT Básico	BAT Modificado
Média	250000	193013,42

Fonte: Elaborado pelos autores.

Observa-se que todas as funções apresentadas anteriormente, tiveram seus parâmetros melhorados, ocasionando em uma evolução significativa no processo de busca, juntamente com a diminuição no processamento de dados, já que todas as simulações tiveram uma redução na quantidade de vezes que a função de teste foi chamada. Apenas uma exceção foi na *Sphere*, onde seus resultados finais mantiveram-se bem semelhantes, não ocasionado em uma melhoria significativa, mas obteve uma diminuição clara na quantidade média de vezes que a função de teste foi utilizada.

6 Conclusões e Trabalhos Futuros

Conclui-se que, para apresentação do algoritmo BAT modificado, precisou-se inserir novas etapas de aperfeiçoamento, ficando comprovado por meio de testes com 5 funções de validação padrão de alta complexidade a obtenção de melhorias significativas no BAT, tanto no processo de busca, já que no desvio padrão, média e mediana dos resultados houve uma redução, como no processamento dos dados, que apresentou uma expressiva diminuição. O BAT, por ser muito poderoso e flexível, abre margem para mais estudos futuros, vislumbrando-se, então, nesta ocasião, a realização de testes com uma diversidade maior de funções referenciadas e verificação dos resultados com o aumento da quantidade de iterações nas novas soluções não aceitas.

Referências

CARLOS, Francisco et al. **Metaheurística Inspirada na Ecolocalização de Morcegos: Aperfeiçoamento e Estudo de Casos**. 2012.

CHOU, Ping-Yi; **TSAL**, Jinn-Tsong; **CHOU**, Jyh-Horng. **Modeling and Optimizing Tensile Strength and Yield Point on a Steel Bar Using an Artificial Neural Network With Taguchi Particle Swarm Optimizer**. 2016, Disponível em: <http://ieeexplore.ieee.org/xpls/icp.jsp?arnumber=7389994> , Acesso em: 26/05/2016.

FARAHANI, Sh. M. et al. **A Gaussian Firefly Algorithm**. 2011.

JANSON, Stefan; **MIDDENDORF**, Martin. **A hierarchical particle swarm optimizer and its adaptive variant**. *IEEE Trans. on Systems, Man and Cybernetics*, Part B, vol. 35, 2005, 1272–1282 p.

SURJANOVIC, Sonja; **BINGHAM**, Derek. **Virtual Library of Simulation Experiments: Test Functions and Datasets**. 2013, Disponível em: <http://www.sfu.ca/~ssurjano> , Acesso em: 22/02/2016.

XIE, Jian; **ZHOU**, Yongquan; **CHEN**, Huan. **A Novel Bat Algorithm Based on Differential Operator and Lévy Flights Trajectory**. *Hindawi*, n. 453812, 2013, 1-2 p.

YANG, Xin-She. **A New Metaheuristic Bat-Inspired Algorithm**. *in: Nature Inspired Cooperative Strategies for Optimization (NISCO 2010)*, (Eds. J. R. Gonzalez et al.), *Studies in Computational Intelligence*, Springer Berlin, 284, Springer, 2010, 65-74 p.

YANG, Xin-She. **Nature-Inspired Metaheuristic Algorithms**. 2. ed. United Kingdom: Luniver Press, 2010.

YANG, Xin-She. **Nature-Inspired Optimization Algorithms**. Elsevier, 2014, 141-154 p.

YILMAZ, Selim; **KUCUKSILLE**, Ecir. **Improved Bat Algorithm (IBA) on Continuous Optimization Problems**. Lecture Notes on Software Engineering, vol. 1, 2013.