

Estudo e Otimização do Modelo SMAP

Study and optimization of the SMAP model

Tiago da Rocha Alves¹

Leone Andrade Campos¹

Ivo Chaves da Silva Junior²

DOI: <https://doi.org/10.34019/2179-3700.2020.v20.31124>

Enviado em: 05/07/2020.

Aprovado em: 19/08/2020.

Resumo

A previsibilidade da vazão disponível para as plantas hidrelétricas alguns dias a frente é de extrema importância para o planejamento e operação do sistema elétrico. É possível obter estas previsões através do uso de modelos hidrológicos que caracterizam a região de estudo. Este trabalho visa aplicar o modelo SMAP a três sub-bacias brasileiras, com o uso de algoritmos de inteligência computacional para a calibração dos parâmetros de chuva. GWO e BA foram os algoritmos utilizados. Os resultados mostraram que o GWO apresentou uma convergência mais rápida, porém os resultados obtidos pelo BA foram melhores.

Palavras-chave: Inteligência Computacional. Modelos Hidrológicos. Otimização. Modelo SMAP. Previsão de Vazão.

Abstract

The predictability of water flows available in hydroelectric plants days ahead is very important for planning and operation of the electric system. It is possible to do this forecast through the application of hydrological models that characterize the region of study. This work aims to apply the SMAP model to three Brazilian sub-basins, with the application of computational intelligence to calibration of rainfall parameters. GWO and BA were used. The results showed that the GWO presented a faster convergence, but the results obtained by the BA were better.

Keywords: Computational Intelligence. Hydrological Models. Optimization. SMAP Model. Waterflow Forecast.

¹Graduandos em Engenharia Elétrica com habilitação em Robótica e Automação. Bolsistas do Programa Institucional de Bolsas de Iniciação Científica (PIBIC/CNPq) da Universidade Federal de Juiz de Fora (UFJF). Contatos respectivos: tiago.alves@engenharia.ufjf.br e leone.andrade@engenharia.ufjf.br.

² Doutor em Engenharia Elétrica pelo Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia da Universidade Federal do Rio de Janeiro (COPPE/UFRJ).

Endereço profissional: Universidade Federal de Juiz de Fora, Faculdade de Engenharia, Departamento de Energia Elétrica. Av. Presidente Costa e Silva, S/N - Galpão 3 - Fac. Engenharia - PPEE - Sala 210 – CEP: 36.036-330 - Juiz de Fora, MG – Brasil



1 INTRODUÇÃO

O parque gerador do sistema elétrico brasileiro é reconhecido pela sua significativa predominância da hidroeletricidade. Diante deste cenário, a qualidade de previsão da vazão natural dos aproveitamentos hidrelétricos tem caráter fundamental para o planejamento e operação do Sistema Interligado Nacional (SIN), pois, a partir dessas informações, são tomadas decisões de operação visando à minimização dos custos e otimização dos recursos disponíveis.

O modelo SMAP (*Soil Moisture Accounting Procedure*) é utilizado para gerar a tendência hidrológica para os modelos de planejamento hidrotérmico de geração de curto prazo. Além disso, o SMAP precisa ser ajustado para cada sub-bacia a ser estudada e, atualmente, o Operador Nacional do Sistema (ONS) faz uso do *Bat Algorithm* (BA), técnica de otimização bioinspirada, a fim de realizar essas acomodações do modelo.

Nesse sentido, o presente trabalho³apresenta um estudo comparativo entre a técnica oficial de otimização do SIN e o *Grey Wolf Optimizer* (GWO), uma técnica, também bioinspirada, mais recente, visando à melhoria da previsão da vazão calculada pelo modelo SMAP para as usinas de Emborcação, Nova Ponte e Corumbá.

Outros autores também já aplicaram técnicas heurísticas na otimização do SMAP. O Algoritmo Genético (AG) foi aplicado na calibração de três bacias do Rio São Francisco (SARAIVA, 2010); os *Dynamically Dimensioned Search* (DDS) e *Shuffled Complex Evolution* (SCE) foram usados para a região do Rio Paraopeba (CAPONI; SILVA; SANTOS, 2011); e, em uma região do semiárido nordestino, a calibração do modelo foi feita utilizando versões do AG, *Particle Swarm Optimization* (PSO) e modelos híbridos de cada um com o algoritmo denominado *Nelder Mead* (RAMPINELLI; COSTA, 2015).

As seções subsequentes estão organizadas da seguinte maneira: metodologia, a qual explana sobre o modelo SMAP e as técnicas BA e GWO; resultados, a qual traz os produtos e as configurações das simulações bem como uma análise destes; e conclusão, que exhibe as inferências decorrentes do trabalho.

³Link para o vídeo do projeto: https://youtu.be/MqveqaWD8_o.

2 METODOLOGIA

2.1 Modelo de transformação chuva-vazão SMAP

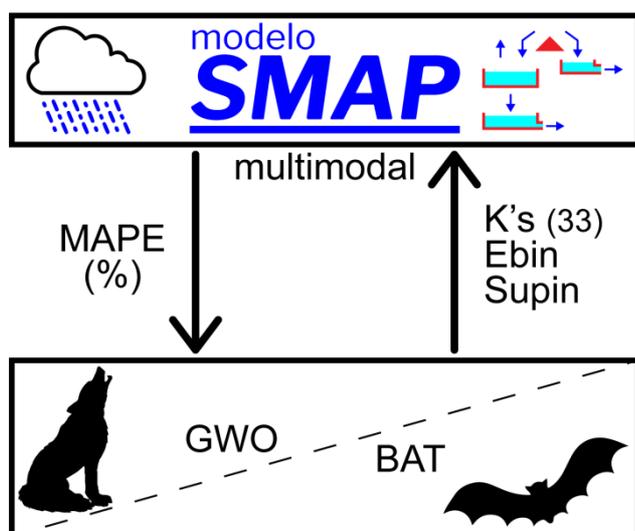
Proposto inicialmente por Lopes, Braga Jr. e Conejo (1982), o SMAP é um modelo determinístico capaz de calcular a vazão disposta em um período de tempo, utilizando valores de precipitações e características previamente calibradas de uma bacia hidrográfica. A sintonização adequada desses valores é fundamental para a acurácia da previsão de vazão do modelo. O foco de estudo de otimização deste trabalho são os parâmetros responsáveis pela adequação da pluviosidade ao modelo, isto é: a vazão básica inicial (Ebin), a vazão superficial inicial (Supin) e 33 coeficientes de ajuste da precipitação (K's).

O processo de otimização ocorre como representado na Figura 1: os 35 parâmetros são usados na execução do SMAP e os resultados do modelo são pontuados pela métrica MAPE (*Mean Absolute Percentage Error*), Equação (1). Esta pontuação, por sua vez, guia a evolução dos algoritmos BA e GWO durante as gerações, as quais originam novos parâmetros que, novamente, são utilizados no SMAP, fechando o ciclo de simulações.

$$MAPE(\%) = \frac{1}{n} \sum_{i=1}^n \left| \frac{Q_{calc} - Q_{obs}}{Q_{obs}} \right| \times 100 \quad (1)$$

Onde Q_{calc} é o valor calculado para vazão, Q_{obs} é o valor observado de vazão e n é o número de dias de vazão avaliados.

Figura 1 – Processo de otimização do modelo SMAP



Fonte: Produção dos autores

2.2 Bat Algorithm (BA)

Proposto por Yang (2010), o *Bat Algorithm* foi bioinspirado na habilidade de ecolocalização dos morcegos, na qual os morcegos emitem pulsos de alta frequência para encontrar e diferenciar obstáculos de diferentes tamanhos e, assim, capturar suas presas. Sendo assim, foi desenvolvida uma analogia matemática a este comportamento para resolução de problemas de otimização. O controle da exploração (busca global) e intensificação (busca local) é feito através dos parâmetros amplitude (A) e frequência (r), respectivamente, em que ambos são alterados no decorrer do processo iterativo. A Figura 2 traz o pseudocódigo do BA para melhor entendimento.

Figura 2 – Pseudocódigo *Bat Algorithm* (BA)

Algoritmo 1: Pseudocódigo Bat Algorithm.

```

1 Inicializar os parâmetros:  $n, \alpha, \lambda$ 
2 Inicialização dos morcegos:  $X_i (i = 1, 2, 3, \dots, n)$ 
3 Avaliação dos morcegos:  $f(X_i)$ 
4 Atualização do melhor morcego:  $X_*^t$ 
5 enquanto não atingir o critério de parada faça
6   para  $i$  de 1 até  $n$  faça
7      $fr_i = fr_{min} + (fr_{max} - fr_{min})\beta, \quad \beta \in [0, 1]$ 
8      $V_i^{t+1} = V_i^t + (X_i^t - X_*^t)fr_i$ 
9      $X_i^{t+1} = V_i^{t+1} + X_i^t$ 
10    se  $rand > r_i, \quad rand \in [0, 1],$  então
11       $X_i^{t+1} = round(X_*^t + \varepsilon \cdot média(A_i^t)), \quad \varepsilon \in [-1, 1]$ 
12    fim
13    Verificar os limites de busca ( $X_i^{t+1}$ )
14    Avaliar o morcego  $f(X_i^{t+1})$ 
15    se  $rand < A_i^t$  e  $f(X_i^{t+1}) \leq f(X_i^t), \quad rand \in [0, 1],$  então
16       $r_i^{t+1} = 1 - exp(-\lambda t)$ 
17       $A_i^{t+1} = \alpha A_i^t$ 
18    fim
19    Atualizar o melhor morcego  $X_*^t$ 
20  fim
21 fim
```

} Etapa de Busca Local

} Etapa de Busca Global

Fonte: Produção dos autores

2.3 Grey Wolf Optimizer (GWO)

O *Grey Wolf Optimizer* (MIRJALILI; MIRJALILI; LEWIS, 2014) é inspirado na hierarquia e nos mecanismos de caça dos lobos cinzentos. As etapas da caçada (busca, encurralamento e ataque) são representadas no GWO através das fases de exploração e intensificação das soluções. Essas fases são regidas exclusivamente pelo parâmetro a^t . Quando $a^t < 1$, tem-se a etapa de intensificação (busca local); e, quando $a^t > 1$, tem-se a etapa de exploração (busca global). A Figura 3 exibe o pseudocódigo do GWO.

Figura 3 – Pseudocódigo do *Grey Wolf Optimizer* (GWO)

Algoritmo 2: Pseudocódigo Grey Wolf Optimization.

```

1 Inicialização dos lobos:  $X_i (i = 1, 2, 3, \dots, n)$ 
2 Avaliação dos lobos:  $F_{ob}(X_i)$ 
3 Definição da hierarquia:  $X_\alpha, X_\beta, X_\delta$ 
4 enquanto não atingir o critério de parada faça
5     Atualizar parâmetro de busca:  $a^t$ 
6     para  $i$  de 1 até  $n$  faça
7          $\vec{A} = a^t \cdot \vec{r}_1 - a^t, \quad \vec{r}_1 \in [0, 1]$ 
8          $\vec{C} = 2 \cdot \vec{r}_2, \quad \vec{r}_2 \in [0, 1]$ 
9          $\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha^t - \vec{X}_i^t|, \quad \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta^t - \vec{X}_i^t|, \quad \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta^t - \vec{X}_i^t|$ 
10         $\vec{X}_1 = \vec{X}_\alpha^t - \vec{A}_1 \cdot \vec{D}_\alpha, \quad \vec{X}_2 = \vec{X}_\beta^t - \vec{A}_2 \cdot \vec{D}_\beta, \quad \vec{X}_3 = \vec{X}_\delta^t - \vec{A}_3 \cdot \vec{D}_\delta,$ 
11         $\vec{X}_i^{t+1} = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}$ 
12        Atualizar a hierarquia dos lobos:  $X_\alpha, X_\beta, X_\delta$ 
13     fim
14 fim

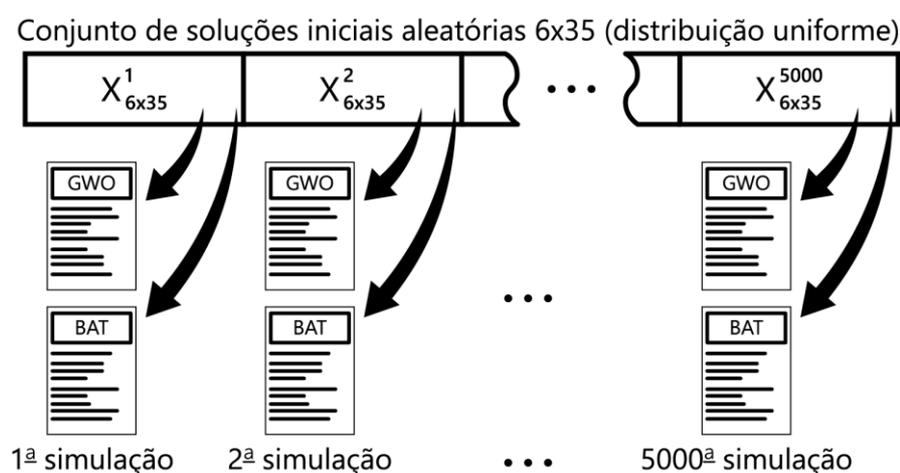
```

Fonte: Produção dos autores

3 RESULTADOS

Foram realizados três estudos de caso: determinação da vazão para as usinas de Emborcação, Nova Ponte e Corumbá. Para ambas as metodologias foram considerados: (i) tamanho da população igual a 6; (ii) convergência pelo número máximo de iterações igual a 3 mil; (iii) foram realizadas 5mil simulações de cada técnica; (iv) ambos os algoritmos partiram sempre das mesmas soluções iniciais para cada uma das 5 mil simulações realizadas (Figura 4). Portanto, foram realizadas 90 milhões de avaliações do modelo SMAP para cada método, isto é, 5 mil simulações \times 3 mil iterações \times 6 indivíduos.

Figura 4 – Inicialização em cada simulação



Fonte: Produção dos autores

3.1 Caso 1: Sub-bacia Emborcação

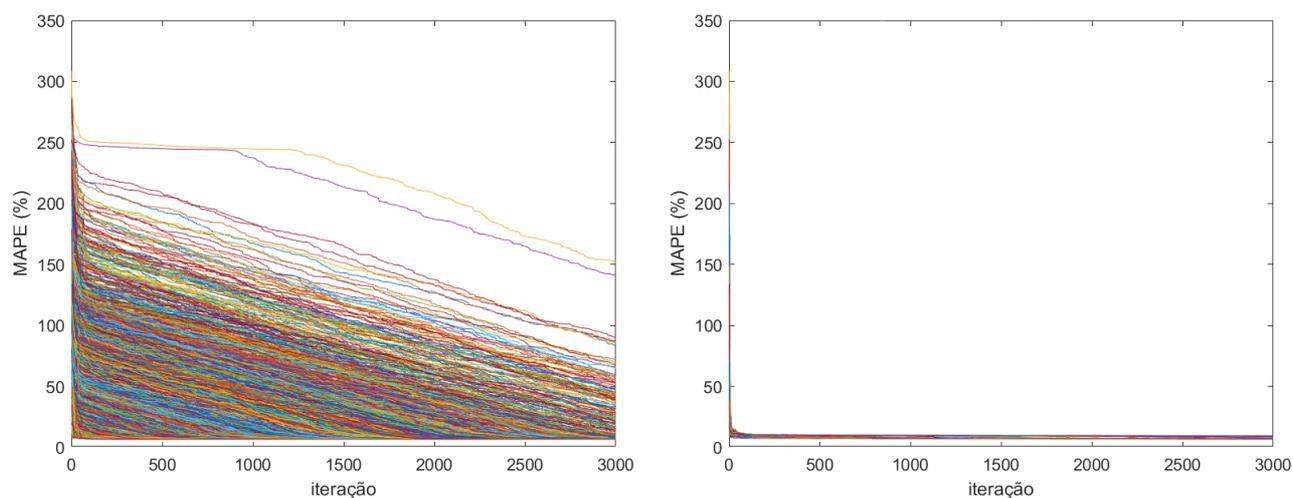
A Figura 5 apresenta os históricos de convergência do BA e GWO, respectivamente, para as 5 mil simulações realizadas. Diante dos resultados apresentados é possível perceber que a fase de exploração do BA ocorre de forma mais lenta do que as apresentadas pelo GWO. Percebe-se que a busca global (exploração da região de solução), feita no início do processo, é bem mais eficiente no GWO, o qual, nas primeiras iterações, já encontra soluções de qualidade aceitável.

Ao comparar os resultados finais das metodologias em estudo (Figura 6), fica evidente o melhor desempenho do BA na obtenção da solução final, o qual gerou o menor valor de MAPE e menor valor de mediana quando contraposto às soluções finais alcançadas pelo GWO. Ou seja, apesar de ter como característica uma fase de exploração

mais lenta, o BA é mais eficaz na etapa de intensificação das soluções (busca local), possibilitando a obtenção de soluções finais de melhor qualidade.

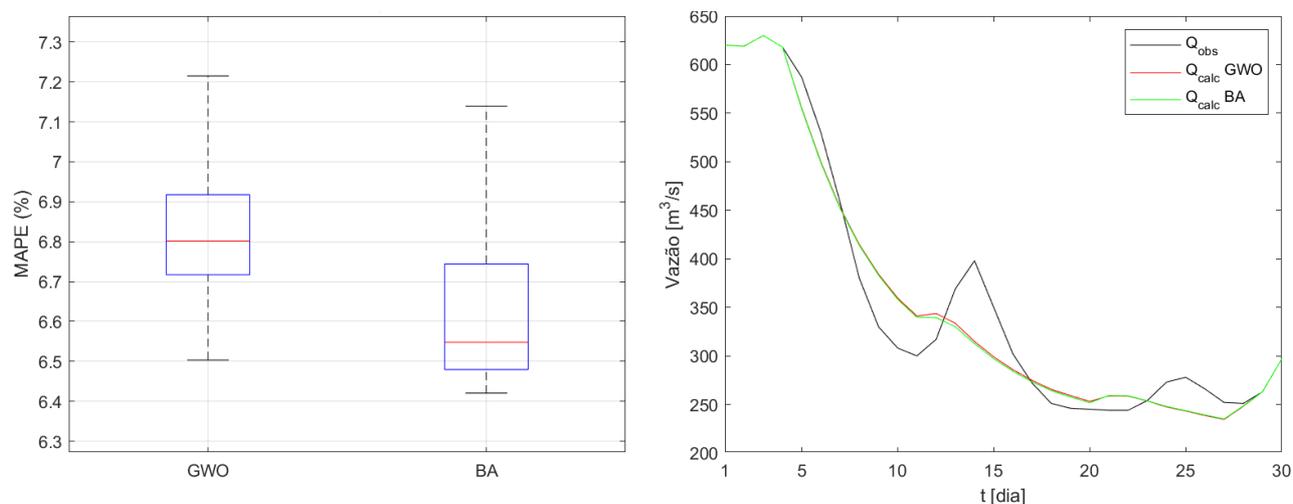
O melhor resultado dentre as 5 mil simulações realizadas das técnicas de inteligência computacional investigadas é apresentado na Figura 6, na qual são comparadas as curvas de vazão calculadas (resultados da otimização do modelo SMAP) com a curva de vazão real observada.

Figura 5 – Gráficos de convergência do BA (esquerda) e do GWO (direita) para a Usina de Emborcação – 5 mil simulações



Fonte: Produção dos autores

Figura 6 – Distribuição dos valores de MAPE sem outliers (esquerda) e vazões calculadas, com BA e GWO, e observada (direita) para a Usina de Emborcação

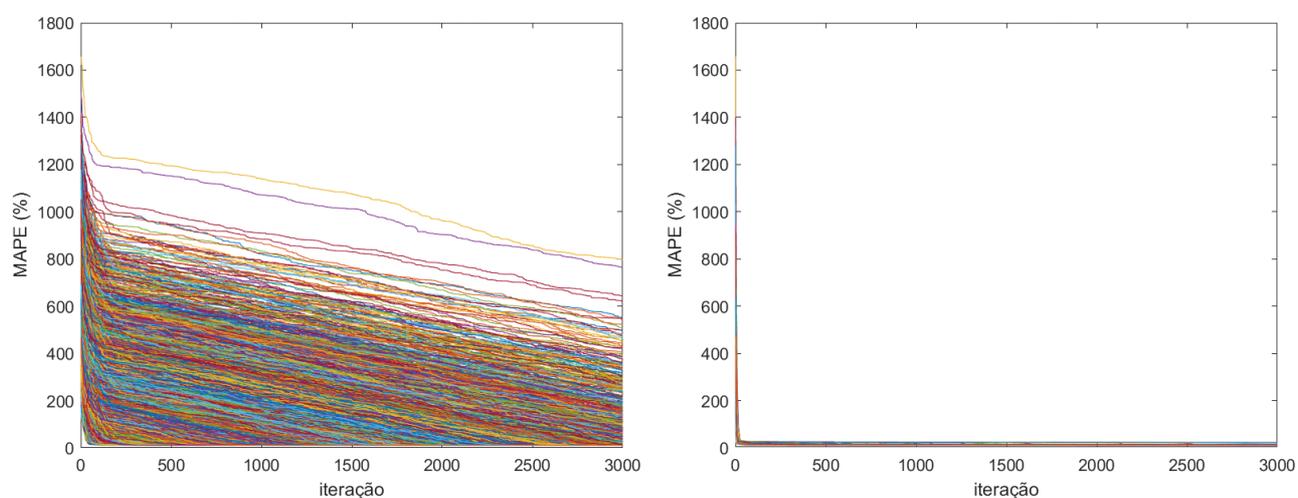


Fonte: Produção dos autores

3.2 Caso 2: Sub-bacia Nova Ponte

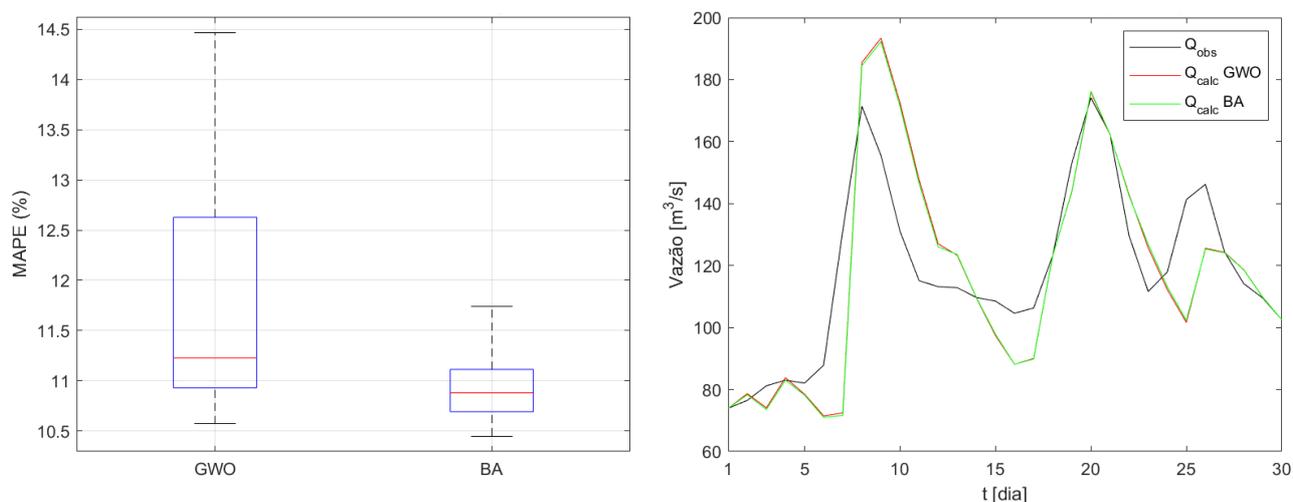
Para Nova Ponte, as metodologias tiveram comportamentos semelhantes ao caso de Emborcação. Méritos para o GWO na etapa de exploração, enquanto o BA obteve na etapa de intensificação seu grande diferencial. Os gráficos de convergências para os algoritmos são exibidos na Figura 7. As comparações entre os MAPEs e as vazões calculadas e observadas são mostradas na Figura 8.

Figura 7 – Gráficos de convergência do BA (esquerda) e do GWO (direita) para a Usina de Nova Ponte – 5 mil simulações



Fonte: Produção dos autores

Figura 8 – Distribuição dos valores de MAPE sem outliers (esquerda) e vazões calculadas, com BA e GWO, e observada (direita) para a Usina de Nova Ponte

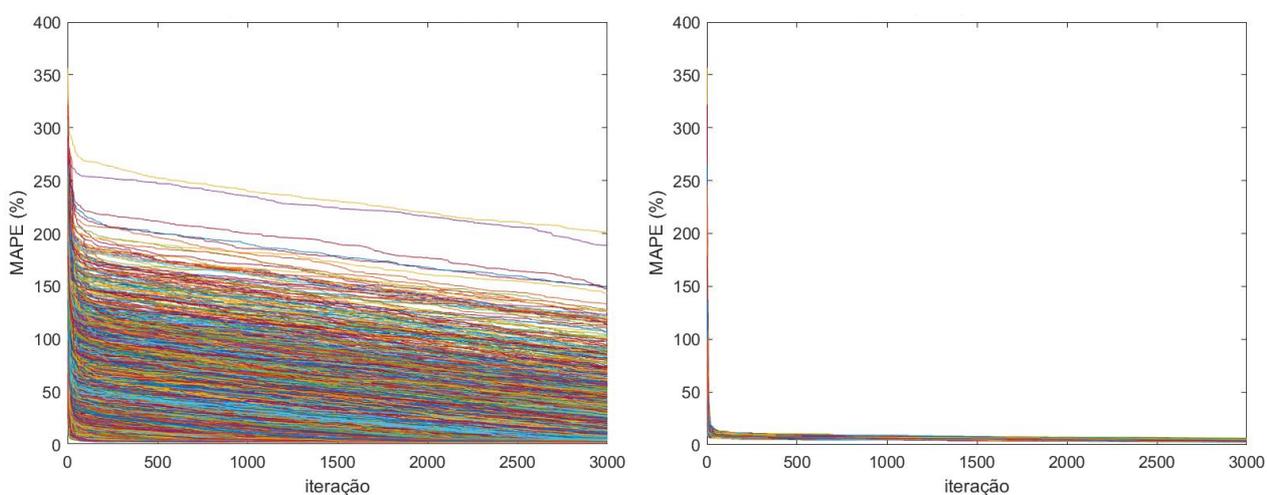


Fonte: Produção dos autores

3.3 Caso 3: Sub-bacia Corumbá

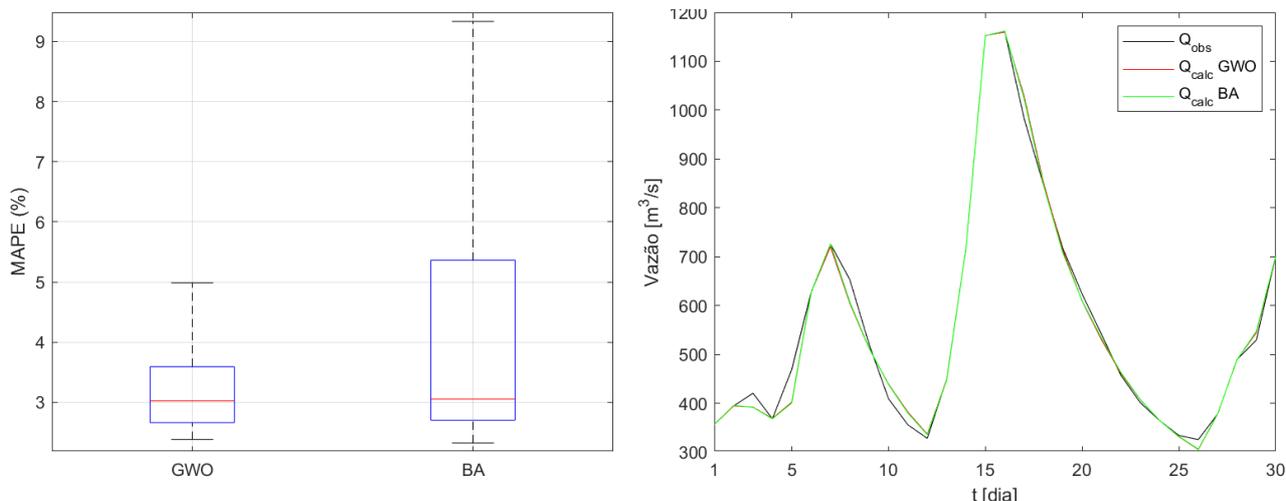
O caso de Corumbá apresenta resultados levemente diferentes dos outros casos. Apesar do BA também gerar o menor valor de MAPE, o GWO obteve uma distribuição menos dispersa dos resultados e um menor valor de mediana. No entanto, o comportamento de convergência de ambos os métodos se manteve, como mostrado na Figura 9 e na Figura 10.

Figura 9 – Gráficos de convergência do BA (esquerda) e do GWO (direita) para a Usina de Corumbá – 5 mil simulações



Fonte: Produção dos autores

Figura 10 – Distribuição dos valores de MAPE sem outliers (esquerda) e vazões calculadas, com BA e GWO, e observada (direita) para a Usina de Corumbá



Fonte: Produção dos autores

4 CONCLUSÃO

Os resultados das simulações realizadas mostram que o GWO é promissor na obtenção de boas soluções logo no início do processo de otimização, característica não observada no BA. Além disso, os resultados do BA apresentaram maior assimetria quando comparados com o GWO e a necessidade de um maior tempo de processamento. Entretanto, o BA proporcionou uma pequena melhora no resultado ótimo de MAPE para os casos analisados: Emborcação, Corumbá e Nova Ponte. Portanto, alternativas metodológicas devem ser investigadas visando melhorar a busca local e a convergência acelerada do GWO logo no início do processo de otimização.

5 AGRADECIMENTOS

Os autores agradecem o apoio da Universidade Federal de Juiz de Fora (UFJF), do Grupo de Otimização Heurística e Bioinspirada (GOHB) e do CNPq.

REFERÊNCIAS

CAPONI, Gabriel Ribeiro; SILVA, Benedito Cláudio da; SANTOS, Afonso Henrique Moreira. Calibração automática de um modelo chuva-vazão mensal por algoritmos genéticos. *In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS*, 19., 2011, Maceió. **Anais**[...].Maceió: [s. n.], 2011.p. 1-18. Disponível em: <https://www.abrhidro.org.br/SGCv3/publicacao.php?PUB=3&ID=81&SUMARIO=1233>. Acesso em: 29 ago. 2020.

LOPES, Joao Eduardo G.; BRAGA JR, B. P. F.; CONEJO, J. G. L. SMAP--a simplifiedhydrologicmodel. *In: SINGH, V. P. (ed.). Applied modeling in catchment hydrology*. Littleton, Colorado: Water Resources Publications, 1982. p. 167-176. ISBN 0-918334-43-8.

MIRJALILI, Seyedali; MIRJALILI, Seyed Mohammad; LEWIS, Andrew. Grey wolf optimizer. **Advances in engineering software**, [s. l.]: Elsevier, v. 69, p. 46-61, Mar. 2014. ISSN 0965-9978

RAMPINELLI, Cássio; COSTA, Magno. Calibração do Modelo Chuva-Vazão SMAP em uma Estação do Semiárido Nordeste com os Algoritmos PSO, AG e Nelder Mead e seus Efeitos na Definição das Séries de Vazões Médias Mensais. *In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS*, 21., 2015, Brasília. **Anais** [...]. Brasília: [s. n.], 2015.p. 1-8. Disponível em: <https://www.researchgate.net/publication/314299601>. Acesso em: 29 ago. 2020.

SARAIVA, Isabel Santos. **Regionalização de parâmetros de modelos de simulação hidrológica para emprego em bacias hidrográficas sem monitoramento fluviométrico**. 2010. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

YANG, Xin-She. A new metaheuristic bat-inspired algorithm. *In*: GONZÁLEZ, J. R.; PELTA, D. A.; CRUZ, C.; TERRAZAS, G.; KRASNOGOR, N. (ed.). **Nature inspired cooperative strategies for optimization (NICSO 2010)**. Berlin, Heidelberg: Springer, 2010. p. 65-74.