

Algoritmos de Segmentação Bio-Inspirados Aplicados a Imagens Médicas de Ultrassom e fMRI

Fernanda S. Beltrame, João Francisco, Lucas Brandon, Ricardo M. Santos,
Guilherme A. Wachs Lopes and Paulo S. Rodrigues
Computer Science Department, Centro Universitário FEI
São Bernardo do Campo, SP, Brazil
{uniffbeltrame,uniejoaojunior,unifltenorio,unifrsantos,gwachs,psergio}@fei.edu.br

Resumo—A área médica é uma das que mais demanda e consome o desenvolvimento de novas tecnologias. Entre os métodos mais desafiadores está a segmentação prévia de imagens médicas em pipelines para diversas aplicações. Uma das técnicas mais utilizadas é a otimização de soluções, que recentemente tem sido realizada com algoritmos bio-inspirados. Tais soluções alcançaram grande sucesso, produzindo o aparecimento de diversos algoritmos novos que, inspirados no comportamento natural de muitas espécies, conseguem alcançar soluções próximas a soluções força-bruta, mas com um tempo computacional bem baixo e aceitável. Entre os algoritmos mais recentes, estão o Krill Herd (KH), Cuckoo Search (CS) e Elephant Herding Optimization (EHO). O presente trabalho propõe a utilização dos algoritmos recentes de otimização KH, CS e EHO em duas bases de imagens médicas. Os resultados indicam que os três algoritmos apresentam performances similares, com o EHO obtendo a melhor performance dentre os três.

Abstract—The medical area is one of those that most demand and consumes the development of new technologies. Among the most challenging methods is the prior segmentation of medical images into pipelines for various applications. One of the most used techniques is the optimization of solutions, which has recently been performed with bio-inspired algorithms. These solutions have achieved great success, producing several new algorithms that, inspired by the natural behavior of many species, can reach solutions close to brute force solutions, but with a very low and acceptable computational time. Among the most recent algorithms are Krill Herd (KH), Cuckoo Search (CS) and Elephant Herding Optimization (EHO). In this work, we propose the use of the recent optimization algorithms KH, CS and EHO in two medical images database. The results indicate that the three algorithms present similar performances, with EHO obtaining the best performance among them.

I. INTRODUÇÃO

Nos últimos anos, uma das áreas que mais tem se beneficiado com o avanço da tecnologia computacional, tanto de hardware quanto de software, é sem dúvida a área médica [7]. Nesse campo, o aprimoramento de algoritmos de processamento de imagens apresenta elevada progressão, corroborando para novas pesquisas, favorecendo o diagnóstico, assim como a precaução e tratamento de patologias [6].

Entretanto, é comum em sistemas baseados em imagens médicas a inclusão de etapas primárias de pré-processamento [9], geralmente para remoção de ruídos, registro de geometrias, segmentação e realce de regiões de interesse ou melhoramento de contraste [10]. No entanto, com o avanço de tecnologias de aquisição, sobretudo para captura e análise de informações

volumétricas como em tomografias e ressonância magnética, atualmente na ordem de 7 Teslas [16], a demanda por maior precisão e velocidade nessas etapas primárias é cada vez mais fundamental. Paralelamente, a aplicação de novos algoritmos de melhoramento de imagens estimula novas gerações de bases de dados médicas [2], cujo objetivo é disponibilizar uma considerável gama de imagens formatadas ou anotadas a fim de comparar resultados de métodos e algoritmos já existentes, além de impulsionar futuras explorações na área.

Atualmente, várias pesquisas têm sido diligentes ao particionamento automático de imagens médicas, sobretudo nos casos envolvendo apenas um canal de cor, tais como ressonância magnética, tomografia computadorizada e raio-x, designadas à pré-análise e/ou construção de superfícies [8]. No entanto, para atingir o objetivo de particionar o espaço de cor considerado, há várias técnicas possíveis de serem utilizadas, dentre elas, o uso de histogramas, geralmente utilizados para distribuir as frequências dos tons de cinza de uma imagem em espaço binário [15]. Não obstante, a utilização de multi-particionamento, às vezes chamada na literatura científica de MLTP (*MultiLevel Threshold Problems*) [13] ainda expõe muitos desafios, visto que há obstáculos referentes à eficiência do algoritmo e à complexidade computacional apresentada, que em alguns casos, pode prejudicar a performance de um sistema de software como um todo.

Assim, com o objetivo de auxiliar nesses problemas, algoritmos de otimização bio-inspirados vêm ganhando cada vez mais espaço, assistindo na produção de resultados aceitáveis que, apesar de produzirem resultados somente próximos dos considerados ótimos, apresentam um tempo computacional muito inferior. Porém, com o desenvolvimento de novos padrões de imagens na área médica, como Dicom e Nii, as soluções que já apresentaram bons resultados em décadas passadas não superaram mais todos os desafios dos dias atuais. Um desses desafios é a utilização dessas soluções em um espaço de busca maior, compatível com os novos padrões de imagens. Visto isso, para ajudar a solucionar esses problemas, a comunidade de otimização tem proposto novos algoritmos inspirados em comportamentos da natureza. Um exemplo de algoritmo pode ser observado em [3].

Os crustáceos, por exemplo, conhecidos na natureza pelas características de viverem em bando e pela busca constante por alimento, foram motivo de inspiração para o surgimento do

Krill Herd Algorithm (KH) proposto por [5] em 2012, gerando novas pesquisas, como a encontrada em [19]. Da mesma forma, o comportamento parasita dos pássaros da família dos *Cuculidade*, conhecidos como *Cuckoo*, que espalham seus ovos em ninhos de outras espécies para enganá-las, forçando-as a criarem a prole alheia, inspirou a criação do *Cuckoo Search via Lévy Flights* (CS), proposto por [20] em 2009, ocasionando novas pesquisas e novos algoritmos como encontrado em [1]. Também, o chamado *Elephant Herding Optimization Algorithm* (EHO), por sua vez baseado no comportamento das manadas de Elefantes, no qual os machos se distanciam dos clãs comandados por matricarcas, foi proposto recentemente por [18] em 2015, e apresenta estudos observados em [14]. Portanto, o KH, CS e EHO são exemplos de algoritmos recentes implementados que baseiam-se nos comportamentos da natureza visando solucionar problemas de otimização existentes. Esses algoritmos ainda não foram, entretanto, implementados utilizando multisegmentação em bases de dados distintas, de forma a compará-los e estudá-los do ponto de vista experimental.

Assim, neste trabalho, esses três novos algoritmos bio-inspirados, KH, EHO e CS, serão aplicados em duas bases de dados de imagens médicas distintas, conhecidas da comunidade científica para estudos em diversos campos. A primeira, mais antiga, é uma base de dados de ultrassonografia mamária com tumores malignos e benignos. Esta primeira base de dados foi utilizada por diversas vezes na literatura [11], [12]. A segunda foi coletada no recente projeto americano *Human Connectome Project, HCP*, que tem por objetivo a captura de imagens do encéfalo humano com tecnologias recentes de tomografia, da ordem de 7 Tesla [4]. Os desempenhos dos três algoritmos são comparados entre si para métodos de segmentação multiníveis (MLTP), chamados assim então de *MultiLevel Threshold Optimization Problem, MLTOP* [13] e com os valores de limiares ótimos obtidos por força-bruta. A função de avaliação será a entropia de Shannon.

Este artigo apresenta a seguinte organização: na Seção II, nós explicamos a métrica de erro médio utilizada para avaliar a performance desses algoritmos. Na Seção III, nós mostramos a aplicabilidade desses novos algoritmos bio-inspirados no problema de segmentação multinível de imagens, particularmente em imagens médicas. A Conclusão é apresentada na Seção IV.

II. COMPARAÇÃO E AVALIAÇÃO DOS RESULTADOS

Neste trabalho, para comparação das aplicações dos três algoritmos considerados para multi-segmentação de imagens, a seguinte ideia de medida de erro será utilizada. Considere uma imagem qualquer I . Para essa imagem, pode-se aplicar um algoritmo de multi-segmentação, cujo resultados pode ser $T_1 = [y_1]$, se for considerado 1 limiar; $T_2 = [y_1, y_2]$, se forem considerados 2 limiares; e $T_3 = [y_1, y_2, y_3]$, se forem considerados 3 limiares. O número de limiares ideal é uma partição do espaço de cor que depende da complexidade da imagem. Na literatura, há trabalhos que indicam que a multilimiarização com poucos limiares possui mais chance de

se aproximar da segmentação humana [13]. Neste artigo, serão demonstradas as comparações com até 3 limiares.

Assim, I possui três conjuntos de limiares ótimos: $\{L_1, L_2, L_3\}$, onde $L_1 = [x_1]$, $L_2 = [x_1, x_2]$ e $L_3 = [x_1, x_2, x_3]$. Supondo que a saída de um dos algoritmos é denotada por $T_i = [y_1, \dots]$, para o cálculo do erro entre a saída obtida T_i e a saída ótima L_i , a seguinte equação é calculada:

$$erro = \frac{\sqrt{\sum_{i=1}^n (x_i - y_i)^2}}{\sqrt{\sum_{i=1}^n x_i^2}} \quad (1)$$

onde $n \in [1, 2, 3]$.

Dessa forma, para cada geração, a Equação (1) é calculada, permitindo a comparação entre as convergências dos três algoritmos para 1, 2 e 3 limiares.

III. EXPERIMENTOS

Para ambos os parâmetros e número de limiares, os seguintes parâmetros foram escolhidos empiricamente:

- *Cuckoo Search*: Número de Ninhos: $n = 40$; Taxa de detecção de pássaros *Cuckoo* pelas vítimas: $pa = 0.5$;
- *Elephant Herding Optimization*: Número de elefantes em cada geração $n = 200$; Número de elefantes escolhidos para a próxima geração: $nkE = 2$; Número de clãs de elefantes $nC = 5$; Fator de influência da matriarca: $\alpha = 0.5$; Influência do ponto central: $\beta = 0.1$;
- *Krill Herd Optimization*: Número de *Krills* para cada geração: $NK = 40$.

Para delimitação do padrão-ouro, foram realizados testes de busca exaustiva, comparando as diferentes possibilidades de segmentação a fim de encontrar a combinação que maximiza a entropia para um, dois e três limiares na segmentação, em ambas as bases, conforme método proposto em [11].

De forma a avaliar a convergência e erro médio de cada geração, os testes foram produzidos variando o número de gerações de três a cem, para cada imagem e cada um dos três limiares de segmentação, nos três algoritmos analisados.

As Figuras 1 e 2 apresentam os gráficos de erro médio para o parâmetro de geração variando de três a cem para um único limiar para ambas as bases. É possível notar que o erro médio do CS para cada geração é consideravelmente maior em relação aos outros algoritmos, consequência de segmentação inapropriada para um único limiar. Entretanto, segmentação multinível de imagens utilizando um único limiar não é usual, o que não afeta a aplicabilidade desse algoritmo em maiores quantidades de limiar. Assim, segmentação multinível com um limiar foi colocada apenas para completude da visualização.

Para construção dos gráficos de performance das Figuras 1 a 6, o eixo horizontal apresenta o número de gerações, enquanto o eixo vertical mostra os pontos de erro médio gerados de acordo com a Equação 1. Cada ponto em um desses gráficos representa o erro médio de todas as imagens na base de dados considerada, seguindo os casos a seguir.

O gráfico de erro médio para a segmentação da base de ultrassom com dois limiares é mostrado na Figura 3, enquanto o gráfico para segmentação com três limiares nesta mesma

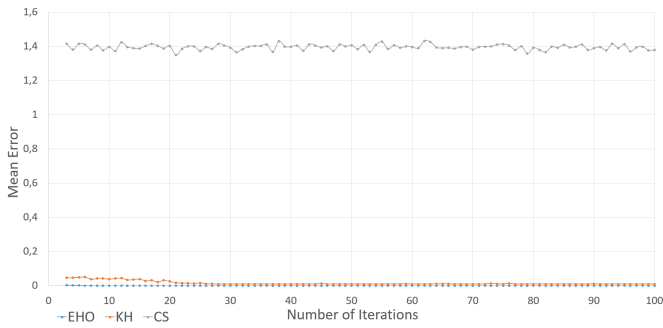


Figure 1. Gráfico de erro médio para segmentação utilizando um limiar na base de ultrassom. Retirada de [17].




Figure 2. Gráfico de erro médio para segmentação utilizando um limiar na base do HCP. Retirada de [17].

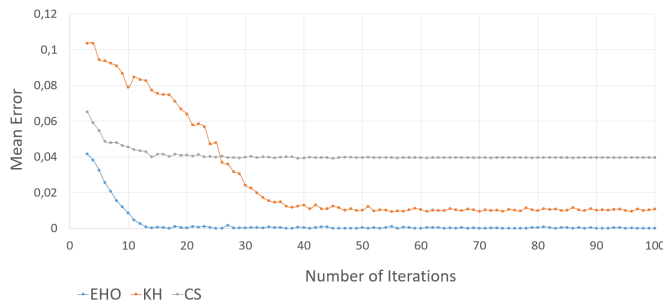


Figure 3. Gráfico de erro médio para segmentação utilizando dois limiares na base de ultrassom. Retirada de [17].




Figure 4. Gráfico de erro médio para segmentação utilizando três limiares na base de ultrassom. Retirada de [17].

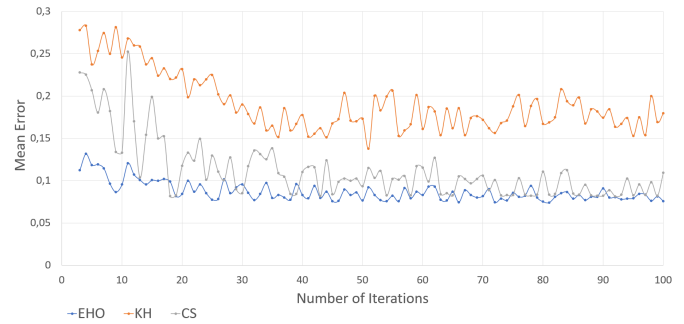


Figure 5. Gráfico de erro médio para segmentação utilizando dois limiares na base do HCP. Retirada de [17].




Figure 6. Gráfico de erro médio para segmentação utilizando três limiares na base do HCP. Retirada de [17].

base é mostrado na Figura 4. Para os parâmetros mencionados nessa Seção, o EHO (cor azul) é o que obtém menor média de erro por geração, além de ser o mais rápido na convergência de valores próximos ao padrão ouro. Por sua vez, o algoritmo KH (cor laranja) inicia as soluções possíveis com maior taxa de erro médio, sendo também aquele que apresenta maior demora na convergência. Entretanto, a convergência no final das iterações é próxima aos resultados do EHO, finalizando em uma posição intermediária dentre os outros dois algoritmos. Finalmente, o CS (cor cinza) iniciou com uma taxa de erro intermediária entre os outros dois algoritmos, convergindo para valores de segmentação distantes do ideal. Dentre os três algoritmos aplicados na base de ultrassom, o EHO foi o que mais se aproximou do resultado modelo, com erro médio por geração igual ou próximo de zero.

Na Figura 5, são mostrados os pontos de erro médio para a base de imagens do HCP com os parâmetros mencionados nessa Seção para a segmentação com dois limiares. Como no gráfico da Figura 3, o algoritmo EHO apresentou o menor erro médio para as primeiras gerações, mantendo a média de erro aproximada para as iterações seguintes. O algoritmo CS iniciou com média de erro intermediária entre os dois outros algoritmos nas primeiras iterações. Apesar do CS se aproximar do EHO na geração $g = 13$, na qual obteve $erro = 0.1036$, próximo ao EHO, com $erro = 0.1009$, a convergência do CS é inconstante quando comparada à do EHO, variando significativamente os valores de limiares escolhidos nas iterações seguintes. O algoritmo KH, por sua

vez, iniciou com maior taxa de erro médio, apresentando, nas próximas gerações, valores de limiar distantes do ideal em relação aos outros dois. Para fins de comparação, na geração $g = 13$, mencionada acima, o KH obteve média de $erro = 0.2587$, distante dos outros algoritmos. Este mesmo comportamento pode ser observado na Figura 6, que mostra a segmentação com 3 limiares na base do HCP. Portanto, o EHO obteve os menores valores de erro médio, convergindo para um valor ideal nas primeiras gerações e seguindo a média para as seguintes.

IV. CONCLUSÃO

Neste artigo, foram analisados três algoritmos de otimização bio-inspirados, sob o ponto de vista da análise assintótica. Além disso, os três algoritmos foram aplicados em imagens médicas e comparados em relação ao erro médio de convergência por iteração, utilizando como função de avaliação a entropia de Shannon. Os experimentos foram realizados em duas bases de dados de imagens médicas distintas, a fim de comparar os resultados dos três algoritmos em processos de multi-segmentação de imagens com um, dois e três limiares. Inicialmente, ao comparar os resultados obtidos para um limiar para ambas as bases, nota-se que os dados obtidos pelo CS não foram próximos do ideal, enquanto os erros médios encontrados pelo EHO e KH foram muito similares ou bem próximos de zero. Porém, esse resultado não afeta possíveis aplicações genéricas do CS, visto que a binarização não é comum em algoritmos bio-inspirados.

Entretanto, ao observar os resultados gerados para dois e três limiares para a base de ultrassom, o KH apresentou, no início, maior taxa de erro comparado aos valores encontrados via busca exaustiva, porém ao avançar as gerações, nota-se que o KH apresentou menores taxas de erro que o CS, o EHO mostrou menor tempo de convergência e taxa de erro, enquanto o CS, para iterações maiores, apresentou maior taxa de erro comparado aos outros dois.

Para dois e três limiares utilizando a base HCP, o EHO foi o algoritmo que mais se aproxima da busca-exaustiva e apresenta as menores taxas de erro. Na visão geral, o KH apresenta as maiores taxas de erro e convergência, enquanto o CS apresenta posição intermediária entre os dois algoritmos.

Nota-se também um desempenho mais estável dos três algoritmos nas bases de HCP comparado com a base de ultrassom. Uma possível hipótese para este comportamento pode estar no fato de que, por apresentar maiores áreas de estabilidade (regiões mais homogêneas), as imagens do HCP apresentam histogramas com maior quantidade de platôs, possibilitando maior amplitude de soluções ótimas. Esta hipótese, no entanto, ainda não foi testada neste trabalho.

Portanto, pode-se concluir que o EHO foi o algoritmo que melhor se comportou para a utilização de multi-segmentação em imagens médicas, possuindo resultados iguais ou bem próximos do padrão-ouro.

V. AGRADECIMENTOS

Agradecimentos à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo - Processo nº 2018/02612-7),

CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e ao Centro Universitário da FEI.

REFERÊNCIAS

- [1] Mohamed Abdel-Basset, Abdel-Naser Hessin, and Lila Abdel-Fatah. A comprehensive study of cuckoo-inspired algorithms. *Neural Computing and Applications*, 29:345–361, 2016.
- [2] A. Ashour, S. Samanta, N. Dey, N. Kausar, W. Abdessalemkaraa, and A. Hassanien. Computed tomography image enhancement using cuckoo search: A log transform based approach. *Journal of Signal and Information Processing*, 6:244–257, 2015.
- [3] Mohamed Abd El Aziz, Ahmed A. Ewees, and Aboul Ella Hassanien. Whale optimization algorithm and moth-flame optimization for multilevel thresholding image segmentation. *Expert Syst. Appl.*, 83:242–256, 2017.
- [4] David C. Van Essen, Stephen M. Smith, Deanna M. Barch, Timothy E.J. Behrens, Essa Yacoub, and Kamil Ugurbil. The wu-minn human connectome project: An overview. *NeuroImage*, 80:62 – 79, 2013.
- [5] Amir Hossein Gandomi and Amir Hossein Alavi. Krill herd: A new bio-inspired optimization algorithm. *Communications in Nonlinear Science and Numerical Simulation*, 17(12):4831 – 4845, 2012.
- [6] R. Nagaraj K. Yamunadevi. An optimized classification of human cancer disease for gene expression data. *International Journal of Advance Research, Ideas and Innovations in Technology*, mar 2018.
- [7] Howard Lee and Yi-Ping Phoebe Chen. Image based computer aided diagnosis system for cancer detection. *Expert Systems with Applications*, 42(12):5356 – 5365, 2015.
- [8] Aiju Li, Yujie Li, Tingmei Wang, and Wenliang Niu. Medical image segmentation based on maximum entropy multi-threshold segmentation optimized by improved cuckoo search algorithm. *2015 8th International Congress on Image and Signal Processing (CISP)*, pages 470–475, 2015.
- [9] Memoona Malik, Faraz Ahsan, and Sajjad Mohsin. Adaptive image denoising using cuckoo algorithm. *Soft Comput.*, 20:925–938, 2016.
- [10] Muthiah Mary, Lekshmi Padma, and Maria John. Modified image segmentation method based on region growing and region merging. *Int. Arab J. Inf. Technol.*, 13:899–907, 2016.
- [11] P. S. Rodrigues and G. A. Giralddi. Improving the Non-Extensive Medical Image Segmentation Based on Tsallis Entropy. *Pattern Analysis and Applications*, 14:1–18, 2011.
- [12] P. S. Rodrigues, G. A. Giralddi, R. F. Chang, and J. Suri. *Automatic Classification of Breast Lesions in 3D Ultrasound Images*, chapter 8, pages 189–223. *Advances in Diagnostic and Therapeutic Ultrasound Imaging*. Artech House, Boston and London, 2008.
- [13] Paulo S. Rodrigues, Guilherme A. Wachs-Lopes, Horst R. Erdmann, Monael P. Ribeiro, and Gilson A. Giralddi. Improving a firefly meta-heuristic for multilevel image segmentation using tsallis entropy. *Pattern Analysis and Applications*, 20:1–20, 2015.
- [14] E. Tuba, A. Alihodzic, and M. Tuba. Multilevel image thresholding using elephant herding optimization algorithm. In *2017 14th International Conference on Engineering of Modern Electric Systems (EMES)*, pages 240–243, June 2017.
- [15] Milan Tuba, Nebojsa Bacanin, and Adis Alihodzic. Multilevel image thresholding by fireworks algorithm. *2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA)*, pages 326–330, 2015.
- [16] A.T. Vu, E. Auerbach, C. Lenglet, S. Moeller, S.N. Sotiropoulos, S. Jbabdi, J. Andersson, E. Yacoub, and K. Ugurbil. High resolution whole brain diffusion imaging at 7t for the human connectome project. *NeuroImage*, 122:318 – 331, 2015.
- [17] G. A. Wachs-Lopes, F. S. Beltrame, R. M. Santos, and P. S. Rodrigues. Comparison of bio-inspired algorithms from the point of view of medical image segmentation. *Proceedings of 2018 IEEE International Work Conference on Bioinspired Intelligence*, July 18-20, 2018.
- [18] Gai-Ge Wang, Suash Deb, and Leandro dos S. Coelho. Elephant herding optimization. *2015 3rd International Symposium on Computational and Business Intelligence (ISCBI)*, pages 1–5, 2015.
- [19] Gaige Wang, Lihong Guo, Amir Hossein Gandomi, Guo sheng Hao, and Heqi Wang. Chaotic krill herd algorithm. *Inf. Sci.*, 274:17–34, 2014.
- [20] Xin-She Yang and Suash Deb. Cuckoo search via lévy flights. In *NaBIC*, 2009.