

# Colônia de Formigas e Busca Local para Definição Automática de Limiar na Segmentação de Imagens<sup>1</sup>

Diogo A. B. Pereira  
Programa de Pós-graduação em  
Engenharia Elétrica e Informática  
Industrial (CPGEI) – (UTFPR)  
Curitiba, Brasil  
diogoutfpr@gmail.com

Ana Cristina B. K. Vendramin  
Programa de Pós-graduação em  
Engenharia Elétrica e Informática  
Industrial (CPGEI), Departamento  
Acadêmico de Informática – (UTFPR)  
Curitiba, Brasil  
cristina@dainf.ct.utfpr.edu.br

Alexandre de A. P. Pohl  
Programa de Pós-graduação em  
Engenharia Elétrica e Informática  
Industrial (CPGEI) – (UTFPR)  
Curitiba, Brasil  
pohl@utfpr.edu.br

## ABSTRACT

This paper presents an image segmentation algorithm based on the ant colony optimization metaheuristic and on a local search. Clustering is used to group image pixels and determines the cluster centers. The local search is applied at the end of each ant solution to improve its quality. Once obtained the best centers the thresholding technique is applied to segment the image. Tests on images corroborate the performance of the metaheuristic with the local search proposed in terms of the segmentation quality.

## Categories and Subject Descriptors

I.4.6 [Image Processing and Computer Vision]: Segmentation - *pixel classification*. I.2.8 [Artificial Intelligence]: Problem Solving, Control Methods, and Search - *heuristic methods*. I.5.3 [Pattern Recognition]: Clustering - *Algorithms*.

## General Terms

Algorithms.

## Keywords

Ant Colony Optimization, Local Search, Clustering, Image Segmentation, Thresholding.

## RESUMO

Esse artigo apresenta um algoritmo de segmentação de imagens que se baseia na meta-heurística de otimização por colônia de formigas e em uma busca local. A técnica de *clustering* é utilizada para agrupar *pixels* de uma imagem e determinar os centros dos grupos formados. A busca local é aplicada no final de cada solução construída por uma formiga para tentar melhorá-la. Uma vez obtidos os melhores centros, a técnica de limiarização é aplicada para segmentar a imagem. Testes em diferentes imagens comprovam o desempenho da meta-heurística com a busca local proposta em termos da qualidade da segmentação.

## 1. INTRODUÇÃO

Entende-se por segmentação de imagens o processo de subdividir uma imagem em regiões de interesse que apresentem características similares. É um tópico emergente, pois se trata de uma ferramenta valiosa na extração de informações e na compressão de dados, além de ter um papel importante em várias áreas de estudo, como, por exemplo, TV digital, reconhecimento de caracteres, visão computacional, entre outros.

Existem diversas técnicas de segmentação, sendo a segmentação binária uma das mais conhecidas. O principal objetivo de tal técnica é classificar os *pixels* da imagem em dois grupos diferentes de acordo com suas características objetivando obter regiões homogêneas. A técnica de limiarização, conhecida também como *Thresholding*, é uma técnica importante para segmentação de imagens e trata-se de um dos métodos de segmentação binária mais simples e rápido empregado em processamento de imagem [1] [2]. Essa técnica é principalmente aplicada quando os objetos desejados apresentam valores de luminância os mais distantes possíveis dos valores do fundo. A técnica é iniciada após a definição do valor do limiar (*threshold*). Com esse valor segue-se para a varredura *pixel a pixel* a fim de verificar se cada *pixel* é considerado pertencente ao objeto ou ao fundo. Por exemplo, se o valor do limiar para a imagem escolhida for cem, todos os valores menores que cem receberão 0 indicando o fundo, já os valores maiores que o limiar receberão 1, pois pertencerão ao objeto. Vale à pena salientar que a definição de valores para os limiares na segmentação de imagens depende, principalmente, do conhecimento dos padrões de repartição espacial dos objetos [3]. Um grande número de métodos para seleção do limiar tem sido proposto, mas a maioria deles propõe uma otimização local e na prática apresenta um resultado não satisfatório [4]. A seleção do limiar através de uma otimização global é um tópico emergente ainda no domínio de processamento de imagens [4] [5]. Em [5] é proposta a segmentação de imagens através da Otimização por Colônia de Formigas (ACO) pura sem busca local e utiliza-se a média dos centros como valor do limiar. Em [4] os autores utilizam a meta-heurística ACO para definir automaticamente a seleção de limiar e comparam com a técnica Ostu, cuja essência é o cálculo da variância entre as classes. Tais autores utilizam no fim do processo uma busca local em 30% da

---

<sup>1</sup> *Ant Colony System and Local Search for the Automatic Threshold Definition on Image Segmentation*

solução e uma probabilidade desta busca ocorrer em 0,1 com o objetivo de melhorar o resultado da busca pelas formigas.

O objetivo do presente trabalho é propor o uso da meta-heurística ACO juntamente com uma técnica de busca local aplicada em cada solução completa construída por uma formiga com o intuito de melhorar a qualidade desta e definir um limiar automático para a segmentação de imagens. Este artigo está organizado em seis seções. A Seção 2 descreve o problema de agrupamento voltado para segmentação de imagens. A Seção 3 apresenta uma breve descrição da meta-heurística ACO. A Seção 4 provê detalhes do algoritmo de ACO e busca local proposto para o problema de segmentação de imagens. A Seção 5 apresenta os resultados preliminares alcançados. Conclusões são providas na Seção 6.

## 2. PROBLEMA DE AGRUPAMENTO NA SEGMENTAÇÃO DE IMAGENS

A técnica de particionamento pode ser citada com um dos métodos mais aplicados no problema de agrupamento. O objetivo desta técnica é agrupar elementos em grupos (*clusters*) [6]. O primeiro passo do processo é a escolha de quantos grupos serão formados. Após, serão selecionados  $m$  objetos que formarão os  $n$  centros iniciais dos grupos sem membros. Segue-se para a escolha dos centros dos objetos, ou seja, cada objeto será atribuído a um grupo. Uma maneira de avaliar a qualidade de um agrupamento é medindo a similaridade entre os objetos de cada grupo através de uma função objetivo. O problema de agrupamento é modelado no presente trabalho como um problema de otimização com o objetivo de encontrar uma atribuição de  $m$  objetos com  $v$  atributos para um dos  $g$  grupos de forma que a raiz quadrada da soma dos quadrados das diferenças entre cada objeto e o seu centro seja minimizada. Tal função objetivo é conhecida como Distância Euclidiana e pode ser vista na Equação (1). Destacam-se as seguintes restrições para o problema: cada objeto deve pertencer a um único grupo e cada *cluster* deve possuir no mínimo um objeto.

$$\text{Minimizar } J = \sum_{i=1}^m \sum_{j=1}^g w_{ij} \sqrt{\sum_{v=1}^v (x_{iv} - c_{jv})^2} \quad (1)$$

Na Equação (1) o elemento  $x_i$  é o vetor do objeto  $i$  e  $x_i \in \mathbb{R}^v$ ;  $c_j$  é o vetor do centro do *cluster*  $j$  e  $c_j \in \mathbb{R}^v$ ;  $x_{iv}$  é o valor do atributo  $v$  do objeto  $i$ ;  $c_{jv}$  é o valor do atributo  $v$  do centro do *cluster*  $j$ , de modo que este valor seja a média dos valores dos atributos  $v$  dos objetos no *cluster*  $j$ ;  $w_{ij}$  é o peso associado ao valor de  $x_i$  com  $c_j$ , sendo que  $w_{ij}$  receberá o valor 1 se o objeto  $i$  estiver agrupado no *cluster*  $j$  e 0 caso contrário. Na segmentação de imagens, o problema consiste em analisar as *pixels* de cada imagem e criar agrupamentos de *pixels* mais similares. Cada *pixel* é considerado como um objeto e os valores dos *pixels* foram normalizados.

## 3. OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS

A meta-heurística ACO foi proposta por [7] [8] como uma técnica baseada no comportamento de insetos sociais com o intuito de resolver problemas de otimização através de uma população de soluções. A técnica copia a maneira como as formigas reais buscam os seus alimentos através do caminho mais curto partindo do seu ninho. A colônia de formigas recebe tarefas sem que haja uma unidade centralizadora de informações. Com isso, o único meio delas se comunicarem e decidir qual caminho percorrer, consiste em trilhas compostas por uma substância química

conhecida por feromônio. Enquanto uma formiga isolada se move aleatoriamente no espaço de soluções, outra que encontre a trilha de feromônio deixada no seu ambiente tende a segui-la, reforçando ainda mais a trilha com seu próprio feromônio [8] [9]. Um sistema de busca inteligente surge através deste comportamento cooperativo e auto-adaptativo das formigas artificiais e é através dele que as formigas coletam de forma paralela as informações necessárias sobre a estrutura do problema, probabilisticamente decidem qual caminho percorrer e constroem um conjunto de soluções. Vale à pena destacar que essas informações necessárias para a tomada de decisão das formigas podem ser informações específicas do problema em estudo, concentração de feromônio e o valor da função heurística.

## 4. ACO E BUSCA LOCAL APLICADOS NO PROBLEMA DE AGRUPAMENTO

O algoritmo de ACO utilizado no presente trabalho se baseia no algoritmo proposto por [10] para agrupamento de dados. Uma técnica de busca local é aplicada juntamente com o algoritmo ao final de cada solução construída por uma formiga na tentativa de melhorar sua qualidade. Ao final do processo a saída do algoritmo é dada pela melhor solução e os centros destas. Os passos executados pelo algoritmo são: a cada movimento, as formigas artificiais selecionam um *pixel* ainda não agrupado e o adiciona a uma solução parcial considerando a intensidade de feromônio e a informação heurística. Esta última indica o desejo de atribuir um *pixel* a um *cluster* em particular e seu valor é obtido calculando o inverso da distância euclidiana entre o *pixel* corrente e cada centro de *cluster* existente. Cada formiga transporta uma matriz de centros e a atualiza após cada *pixel* ser agrupado. Para selecionar um *cluster*  $j$  para um *pixel*  $i$ , uma dentre duas estratégias podem ser adotadas dependendo do resultado da Equação (2): (a) Intensificação: permite que as formigas se movam de forma gulosa para um centro cujo produto do nível de feromônio e heurística seja mais alto (ver Equação (2)); (b) Exploração: permite que uma formiga escolha um centro de forma estocástica (ver Equação (3)). Quanto mais promissor um centro for, maior será a probabilidade de este ser escolhido.

$$j = \begin{cases} \arg \max_{j \in N_i} \{ [\tau(i, j)]^\alpha [\eta^k(i, j)]^\beta \} & \text{se } q \leq q_0 \\ S & \text{caso contrário} \end{cases} \quad (2)$$

Na Equação (2)  $q_0$  representa uma prioridade atribuída a priori,  $q$  é uma probabilidade gerada aleatoriamente,  $N_i$  é o conjunto de *clusters* disponíveis e  $S$  é escolhido de acordo com a Equação (3) sendo que  $P^k(i, j)$  é a probabilidade de atribuir o *pixel*  $i$  ao *cluster*  $j$ .  $[\tau(i, j)]^\alpha$  é expresso como a intensidade de feromônio na ligação  $(i, j)$  indicando o quão útil essa atribuição foi no passado,  $[\eta^k(i, j)]^\beta$  indica o valor da função heurística para a formiga  $k$  calculada por  $\eta^k = \frac{1}{d^k(i, j)}$  onde  $d^k(i, j)$  representa a distância euclidiana entre o *pixel*  $i$  e o centro  $j$  de uma formiga  $k$  e é dado por  $d^k(i, j) = \sqrt{\sum_{v=1}^v (x_{iv} - c_{jv})^2}$ .  $\alpha$  e  $\beta$  são constantes positivas utilizadas para indicar a influência das concentrações de feromônio e da heurística empregada, respectivamente.

$$P^k(i, j) = \frac{[\tau(i, j)]^\alpha [\eta^k(i, j)]^\beta}{\sum_{j=1}^g [\tau(i, j)]^\alpha [\eta^k(i, j)]^\beta} \quad (3)$$

A cada escolha de um centro para um *pixel*, a informação de cada formiga é atualizada e o centro do *cluster* cujo *pixel* foi

adicionado é recalculado. Uma vez atribuído todos os *pixels* a um dos centros de *clusters* existentes, isto é, uma vez construída uma solução, calcula-se o valor da função objetivo (FO) de cada formiga  $J_k$  (ver Equação (1)). Nesse momento, a técnica de busca local proposta no presente artigo é aplicada com o intuito de melhorar a solução encontrada pela formiga.

Os seguintes passos são executados pela busca local: (1) Percorrem-se todos os *pixels*  $m$  da solução final construída pela formiga  $k$ ; (2) Compara-se o *pixel*  $m$  com cada um dos centros de *clusters* para verificar com qual dos centros ele mais se assemelha (FO); (3) Se o *pixel*  $m$  for mais semelhante ao centro de *cluster* para o qual não foi atribuído pela formiga  $k$ , realiza-se a troca para o novo centro. Caso contrário, o *pixel* continua no *cluster* para o qual a formiga  $k$  havia atribuído; (4) Se a busca local já percorreu todos os *pixels*, o algoritmo vai para o passo 5, senão volta para o passo 2; (5) Após realizar todas as trocas necessárias, calcula-se a FO; Se a nova solução encontrada pela técnica de busca local for melhor que a solução da formiga ( $J_k$ ), a nova solução será aceita e as variáveis do ACO serão substituídas pelas novas variáveis da busca local. Caso contrário, o ACO permanece com os dados da formiga  $k$  inalterados.

Após todas as formigas de cada iteração construírem suas soluções e aplicá-las na busca local, as  $k$  soluções são ordenadas através dos valores de suas funções objetivos  $J_k$ . A melhor solução é considerada a melhor solução da iteração corrente. Esta solução é comparada à melhor solução encontrada até o momento e a melhor delas será a nova solução melhor. Nesse momento, a regra de atualização global é aplicada e somente as formigas elites (melhor solução) poderão adicionar feromônio no final de cada iteração. O feromônio é atualizado da seguinte forma:  $\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \sum_{k=1}^K \Delta\tau_{ij}^k$ . Onde: (a)  $\rho$  é a taxa de evaporação de feromônio,  $0 < \rho < 1$ ; (b)  $t$  é o número da iteração; (c)  $K$  é o número de formigas elites; (d)  $\Delta\tau_{ij}^k$ , diferente do trabalho de [10] é determinado pelo inverso da função objetivo  $J_k$  dividido pelo número de objetos existentes ( $m$ ):  $\Delta\tau_{ij}^k(t) = \frac{1}{J_{ij}^k(t)}$  se o *pixel*  $i$  for atribuído ao centro  $j$ . Quando o algoritmo exceder o número máximo de iterações pré-definido ou quando não houver mais melhora na solução após 10 iterações consecutivas, ele é finalizado e a melhor solução encontrada e os centros desta são retornados. O próximo passo, diferente do trabalho de [10] que é voltado apenas para agrupamento de dados, é a utilização da técnica de Limiarização para segmentação de imagens.

A técnica de limiarização é utilizada para segmentar imagens e é calculada pela Equação (4) [1], onde  $f(x,y)$  é o valor do *pixel* na coordenada  $x$  e  $y$ ;  $T$  é valor do limiar;  $g(x,y)$  é a saída do *pixel* da imagem limiarizada. Através do uso desta técnica é possível distinguir um fundo do objeto (os *pixels* rotulados com 1 correspondem aos objetos e os *pixels* rotulados com zero correspondem ao fundo). A segmentação é realizada percorrendo *pixel* a *pixel* da imagem e atribuindo o valor 0 ou 1. O valor  $T$  é calculado pela Equação (5) [1].

$$g(x,y) = \begin{cases} 1, & \text{se } f(x,y) > T \\ 0, & \text{se } f(x,y) \leq T \end{cases} \quad (4)$$

$$T = \frac{\sum_{i=1}^n c[i]}{n} \quad (5)$$

Na Equação (5),  $n$  representa a quantidade de centros;  $c[i]$  representa o valor do centro  $i$ . A entrada é dada pelos valores dos

centros das melhores soluções e com isso obtêm-se de forma automática o valor do limiar que será utilizado para segmentação de imagens através da Limiarização.

## 5. RESULTADOS PRELIMINARES

Para avaliar a qualidade do algoritmo proposto, aplicou-se a técnica sobre três imagens: Lena, Células e Mancha. A imagem da Lena, apresentada na Figura 1a, cujo tamanho é de 102 *pixels* de largura por 102 *pixels* de altura, totaliza 10404 *pixels* na imagem. A imagem Células é apresentada na Figura 1b com 128 de largura por 87 de altura, apresentando 11136 *pixels*. Já a imagem Mancha, apresentada na Figura 1c tem como dimensão 133 de largura por 134 de altura, apresentado 17822 *pixels*.

As três imagens estão em escala de cinza e os valores dos *pixels* foram normalizados. A configuração de parâmetros para aplicação nestas imagens foi: (1) Fator  $\alpha$  que indica a influência nas concentrações de feromônio: 1; (2) Fator  $\beta$  que representa a influência da função heurística: 5; (3) Variável de controle  $\rho$  que representa a influência do fator de evaporação: 0,5; (4) Número de formigas: 5; (5) Número de repetições: 10; (6) Número de iterações: 100; (7) Quantidade de Centros de *Clusters*: 2. (8) Fator  $q_0$  que é responsável pela probabilidade de intensificação: 0,8; (9) Inicialização dos centros: os mais distantes possíveis; (10) ACO puro ou ACO com busca local.




Figura 1. Imagens utilizadas no experimento: (a) Lena, (b) Células e (c) Mancha.


Tabela 1 – Valor das soluções para ACO puro e ACO com Busca Local.

Imagem	ACO com Centros Distantes	Melhor Solução	Pior Solução	Média Soluções
Células	Puro	527,5200	530,4130	528,5735
	Busca Local	500,6368	517,1052	511,1417
Lena	Puro	925,9005	978,8084	933,2082
	Busca Local	886,5192	901,0466	891,3682
Mancha	Puro	798,2439	509,3467	804,4632
	Busca Local	787,9989	788,1760	788,1141

Após a definição dos parâmetros a serem executados pelo algoritmo parte-se para a demonstração dos resultados (ver Tabela 1) considerando a função objetivo da Equação (1). Como pode ser visto na Tabela 1, os melhores resultados para as imagens foram 500,6368 para a imagem Células, 886,5192 para a imagem Lena e 787,9989 para a imagem Mancha todos quando aplicado a busca local juntamente com a técnica do ACO. Após obter os resultados seguiu-se para a utilização do algoritmo de Limiarização. Através da Tabela 1 decidiu-se que os valores de centros a serem utilizados para o cálculo do limiar (Equação (4)) seriam os dos melhores resultados encontrados em termos da FO, ou seja, as soluções obtidas quando se utilizou o ACO com Busca Local. Os centros e os valores de limiar para as três imagens podem ser vistos na Tabela 2. Após obter os dados dos limiares, parte-se para a segmentação das imagens utilizando tais valores (ver Figura 2).

**Tabela 2 – Valor dos Centros das Melhores Soluções**

Imagem	Centro 1	Centro 2	Limiar
Células	143	117	130
Lena	116	52	84
Mancha	135	67	101



**Figura 2. Imagens segmentadas: (a) Lena ( $T = 84$ ), (b) Células ( $T = 130$ ) e (c) Mancha ( $T = 101$ ).**

## 6. CONCLUSÃO

O presente artigo apresentou uma técnica para definição automática de limiar através da utilização da meta-heurística de otimização de colônia de formigas acoplado a uma técnica de busca local. O primeiro passo do processo consistiu na aplicação do conceito de agrupamento para juntar os *pixels* da imagem segundo sua similaridade (valores de luminância). O espaço de busca foi modelado de modo que as formigas do ACO escolham para cada *pixel* um dos centros dos grupos disponíveis. O processo de busca do ACO permite investigar soluções ainda não encontradas de modo a explorar melhor o espaço de busca e evitar que o algoritmo caia em um ótimo local. Experimentos foram executados para comprovar a eficiência do algoritmo proposto em termos da função objeto. Através desses experimentos foi palpável perceber a qualidade da solução quando aplicada uma busca local juntamente com o ACO. O próximo passo foi dado pelo cálculo do limiar, onde os centros das melhores soluções para cada imagem foram utilizados. Em seguida, foi utilizado o algoritmo de

Limiarização com o limiar calculado anteriormente para a segmentação da imagem. O algoritmo proposto mostrou-se, então, eficiente na segmentação de imagens.

Como trabalhos futuros sugerem-se: aplicação da técnica em imagens ruidosas; uso de outras imagens para teste; estudo e comparação de outras medidas para avaliar a qualidade das soluções candidatas; comparação da técnica de ACO com outras técnicas de inteligência artificial. Por fim, esse artigo pode ser considerado um ponto inicial para os futuros estudos sobre a segmentação de vídeo digital através dos seguintes passos: 1) ajuste do algoritmo proposto (ACO com busca local) para uso na segmentação de vídeo digital levando em consideração a variável temporal; 2) avaliação da qualidade do vídeo digital frente a ocorrências de diferentes artefatos como borramento, blocagem, entre outros; 3) estudo e aplicação de medidas para avaliar a qualidade de vídeos digitais; 4) testes subjetivos aplicados com usuários leigos e especialistas com o intuito de comparar os resultados destes com a avaliação objetiva obtida no passo 3; 5) uso de informações da segmentação para comprimir os vídeos acarretando em economia de custo para o tráfego das informações.

## 7. REFERÊNCIAS

- [1] Gonzalez, R. C. e Woods, R. E. 2000. *Processamento de imagens digitais*. Editora Edgard Blucher, São Paulo. ISBN 85-212-0264-4.
- [2] Zou, R., Yu, W., Yu, Z., e Yu, X. 2009. Image Segmentation Based on Local Ant Colony Optimization. *Fifth International Conference on Natural Computation, ICNC '09*, 2009, vol.3, 35-39.
- [3] Corte, A. P. D., Dlugosz, F. L., Centeno, J. A. S. 2008. Testes de Limiares para Segmentação de Imagens SPOT-5 Visando a Detecção de Plantios Florestais. *Revista Acadêmica: Ciências Agrárias e Ambientais*. ISSN: 0103-989X, v.6, n.2, 2008.
- [4] Ye, Z., Zheng, Z., Yu, X. e Ning, Xiaogang. 2005. Automatic threshold selection based on ant colony optimization algorithm. *Neural Networks and Brain, 2005. ICNN&B '05. International Conference on*, vol.2, 728-732, 13-15 Oct. 2005. DOI:10.1109/ICNNB.2005.1614730
- [5] Zhao, B., Zhu, Z., Mao, E. e Song, Z. 2007. Image Segmentation Based on Ant Colony Optimization and K-Means Clustering. *Automation and Logistics, 2007 IEEE International Conference on*, 459-463, 18-21 Aug. 2007. doi: 10.1109/ICAL.2007.4338607
- [6] Bramer, M. 2007. *Principles of Data Mining*. Springer.
- [7] Dorigo, M. 1992. *Optimization, Learning and Natural Algorithms*. PhD thesis, Politecnico di Milano.
- [8] Dorigo, M., Maniezzo, V. e Colomi, A. 1996. The Ant System: Optimization by a Colony of Cooperating Agents. *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, vol. 26, n. 1, 1-13.
- [9] Dorigo, M. 1994. Learning by Probabilistic Boolean Networks. *Proceedings of the IEEE International Conference on Neural Networks*, 887-891.
- [10] Kao, Y. e Cheng, K. 2006. An ACO-Based Clustering Algorithm. *Lecture Notes in Computer Science*, vol. 4150, 340-347, Springer.