

Comparação entre as Técnicas de Agrupamento K-Means e Fuzzy C-Means para Segmentação de Imagens Coloridas

Vinicius Ruela Pereira Borges¹

¹Faculdade de Computação - Universidade Federal de Uberlândia (UFU)
CEP 38.400-902 – Uberlândia – MG – Brasil

viniciusrpb@mestrado.ufu.br

Abstract. *This paper makes a comparative study about two known clustering techniques used in color image segmentation: K-Means and Fuzzy C-Means. It will be described in details the adaptation of each method to digital image processing, like too your methodologies and steps that are involved. Furthermore, two methods are presented for this these techniques, which can be used to find an ideal quantity clusters that will be generated. The experiments were performed with nature images, varying the cluster quantity and results showed the specific particularities of each method.*

Resumo. *Este artigo faz um estudo comparativo entre duas conhecidas técnicas de agrupamento utilizadas na segmentação de imagens coloridas: K-Means e Fuzzy C-Means. Será descrita em detalhes a adaptação de cada método para o processamento de imagens digitais, como também suas metodologias e etapas que as constituem. Além disso, são apresentados dois métodos para validação para estas técnicas, que podem ser utilizados para encontrar uma quantidade ideal de agrupamentos a serem gerados. Os experimentos foram realizados em imagens naturais, variando-se o número de agrupamentos e os resultados mostraram as particularidades específicas de cada método.*

1. Introdução

A segmentação de imagens está presente em muitas aplicações que envolve processamento de imagens digitais, como a análise de imagens médicas, reconhecimento de faces, sistemas de controle de tráfego rodoviário, reconhecimento de escrita, identificação de regiões em imagens de satélite etc.

O processo de segmentação consiste em subdividir a imagem em regiões ou objetos que a constituem. Seu objetivo é simplificar ou alterar a representação de uma imagem, com a finalidade de facilitar sua análise. Para isso, existem diversos métodos capazes de realizar tal função, nos quais destacam-se técnicas baseadas similaridade (*threshold*), detecção de descontinuidades, agrupamento de dados (*clustering*), crescimento de regiões, método da divisão-fusão, entre outras.

Neste artigo, serão tratadas e comparadas duas técnicas de agrupamento para a segmentação de imagens: K-Means e Fuzzy C-Means. Estes métodos possuem paradigma de aprendizado não-supervisionado, ou seja, procuram determinar e identificar automaticamente como os dados estão organizados em um conjunto ou em uma base de dados [Duda et al. 2000]. O K-Means é um método de agrupamento que tem como objetivo encontrar K grupos (padrões, ou regiões) na imagem. Estes grupos são representados por

centróides, que são médias numéricas de todos os *pixels* pertencentes ao agrupamento em questão. Possuindo uma idéia de funcionamento análoga ao *K-Means*, o *Fuzzy C-Means* utiliza um grau de relação para medir a similaridade entre cada *pixel* e cada padrão existente na imagem. Quanto mais próximo do valor unitário, maior é o indício de que o *pixel* pertença ao agrupamento em questão. Se for mais próximo de zero, significa que são pequenas as chances do *pixel* pertencer ao agrupamento analisado. Por isso, é conhecido como a versão *fuzzy* do *K-Means*, pois permite que um dado possua relação com cada padrão da imagem.

Os métodos foram testados em imagens naturais, que são figuras que possuem diversas cores, elementos e objetos em sua composição. Segmentar estes tipos de imagens são um desafio, visto que as cores variam bastante e os objetos podem estar distribuídos de qualquer maneira pela imagem. Com base nisso, podem existir diversos tipos de padrões ou regiões em uma imagem natural. Sabendo-se que esta quantidade é desconhecida *a priori* e que os métodos *K-Means* e *Fuzzy C-Means* requerem como parâmetro o número de agrupamentos a serem gerados, são apresentados critérios para a validação de agrupamentos, que medem a qualidade de uma partição obtida pelo algoritmo de agrupamento.

O restante do artigo está organizado como se segue. A Seção 2 descreve em detalhes cada algoritmo de agrupamento adaptado para a segmentação de imagens digitais. A Seção 3 faz um breve relato sobre os critérios de validação de agrupamentos. A Seção 4 analisa os resultados obtidos por cada um dos métodos e ilustra a aplicação dos critérios de validação apresentados. A Seção 5 descreve as considerações finais e a última Seção lista as Referências Bibliográficas.

2. Agrupamento de Dados

A idéia dos algoritmos estudados é fornecer uma classificação de informações de acordo com os próprios dados, baseada em análises e comparações entre os seus valores numéricos. Desta maneira, o algoritmo classifica os dados automaticamente, sem a necessidade de supervisão, o que caracteriza um paradigma de aprendizado não-supervisionado.

Antes de iniciar a descrição das técnicas *K-Means* e *Fuzzy C-Means*, ressaltam-se algumas considerações. O espaço de características é formado pelos canais de cores vermelho (R), verde (G) e azul (B) não-normalizados de uma imagem I composta por N *pixels*. Assim, os valores $I(q)^R$, $I(q)^G$ e $I(q)^B$ fornecem a intensidade no intervalo $[0, 255]$ para os canais de cor vermelho, verde e azul, respectivamente, para o q -ésimo *pixel* ($1 \leq q \leq N$) desta imagem I .

2.1. K-Means

O *K-Means* [Samma e Salam 2009] [Tan et al. 2006], é um algoritmo muito popular utilizado para agrupamento de dados. Além de ser bastante simples, funciona bem na prática sendo base de vários outros métodos de agrupamento. O objetivo deste método é particionar a imagem em uma quantidade K de agrupamentos, minimizando a distância *intra-clusters* e maximizando a distância *inter-clusters*.

Seu funcionamento é simples. Primeiramente, deve-se escolher K centróides iniciais, que representam os centros dos K agrupamentos dados por C_1, \dots, C_K , onde $K \geq 2$. Agora cada *pixel* da imagem é rotulado em relação ao centróide da classe mais similar. Por conseguinte, os centróides tem seus valores atualizados com base nos *pixels* que passaram a pertencer aos respectivos agrupamentos. Assim, o processo se repete enquanto

um critério de parada não for satisfeito. Neste trabalho, o algoritmo termina sua execução quando os centróides permanecerem inalterados entre duas iterações. O algoritmo é composto pelas seguintes passagens:

1. Primeiramente, os K centróides (c_1, \dots, c_K) devem ser inicializados. Neste trabalho, utilizou-se uma inicialização aleatória que é feita pela seguinte fórmula

$$c_i^h = i \frac{255}{K}, \text{ onde } 1 \leq i \leq K \quad (1)$$

para cada $h \in \{R, G, B\}$;

2. Para cada *pixel* q da imagem I
 - Calcule a distância Euclidiana entre o *pixel* q e cada centróide. Esta distância tem como objetivo obter um valor que determina a dissimilaridade entre dois objetos. De maneira geral, a distância Euclidiana entre dois objetos x e y com dimensão w é dado por:

$$D(x, y) = \sqrt{\sum_{l=1}^w (x_l - y_l)^2} \quad (2)$$

Adaptando-se a equação (2) para o *pixel* q e um centróide i no espaço de características RGB , tem-se que

$$D(I(q), i) = \sqrt{(c_i^R - I(q)^R)^2 + (c_i^G - I(q)^G)^2 + (c_i^B - I(q)^B)^2} \quad (3)$$

- Encontre o centróide k com a menor dissimilaridade e classifique o *pixel* como pertencente ao agrupamento k ;
3. Nesta etapa, os centróides de todos os K agrupamentos tem seus valores recalculados. Para isso, a média aritmética do i -ésimo centróide é calculada entre os *pixels* da imagem classificados como pertencentes ao agrupamento i :

$$c_i^h = \frac{1}{|C_i|} \sum_{q \in C_i} I(q)^h \quad (4)$$

tal que C_i é o agrupamento representado pelo centróide c_i e $|C_i|$ é a cardinalidade C_i ;

4. Retorne ao Passo 2 até que todos os centróides não alterem seus valores entre duas iterações.

Em contraste com a simplicidade de seu funcionamento, destacam-se algumas desvantagens. O método é altamente dependente da inicialização dos centróides, onde uma determinada posição inicial pode levar a solução para um ótimo local. Cita-se também o fato de que problemas podem ocorrer quando os agrupamentos possuem diferentes tamanhos, densidades e formas não-globulares no espaço de características.

Observa-se que o algoritmo K -Means realiza uma classificação *hard*, pois cada *pixel* é classificado como membro de um único agrupamento. Assim, os *pixels* de uma imagem podem ser similares a um determinado centróide, ou podem se encontrar equidistantes entre dois centróides. Neste último caso, podem ocorrer erros de classificação, sendo adequado adotar métodos que abordam classificação *soft*, como a técnica *Fuzzy C-Means*, analisada a seguir.

2.2. Fuzzy C-Means

O Fuzzy C-Means [Sato-Ilic e Jain 2006] é um método de agrupamento que permite que um certo dado possua um determinado grau de relação com cada um dos C agrupamentos que se deseja obter. Pode-se dizer que este algoritmo possui uma abordagem *soft*, pois um dado não está associado exatamente com um único padrão da imagem.

O grau de relação (também chamado de grau de pertinência) entre um *pixel* da imagem e um agrupamento é um valor que está no intervalo $[0, 1]$. Um grau de pertinência próximo a 1, significa que o *pixel* e o agrupamento em questão são similares. Caso contrário, esse valor estará próximo a zero, o que indica dissimilaridade entre o *pixel* e o agrupamento analisado.

O algoritmo Fuzzy C-Means possui funcionamento e estrutura semelhantes ao K-Means. Neste método, deve-se minimizar uma função Objetivo, que determina que os dados mais próximos aos centróides estejam associados à funções de pertinência maiores e vice-versa. Vale ressaltar que o cálculo dos centróides utiliza a função de pertinência, que é atualizada constantemente até a convergência do algoritmo. Esta etapa de atualização é equivalente à etapa de atribuição de padrão aos *pixels* da imagem no K-Means (Passo 3). As etapas deste algoritmo são as seguintes, onde n é o passo do tempo:

1. Inicie as variáveis, constantes e função Objetivo: m , que é um peso constante que influencia no valor de pertinência, J^0 , que é o valor inicial da função Objetivo e ϵ , que é um limiar para determinar se J foi suficientemente minimizada. Neste trabalho, $m = 2$, $J^0 = 0$ e $\epsilon = 1$;
2. Inicie a matriz graus de pertinência U com valores aleatórios, onde $U(q, i)$ se refere ao grau de pertinência entre o *pixel* q e o agrupamento i , respeitando-se as condições de que para cada *pixel* q da imagem $\sum_{i=1}^C U(q, i) = 1$ e para cada agrupamento i , $0 \leq \sum_{q=1}^N U(q, i) \leq N$, sendo que $1 \leq i \leq C$;
3. Para cada canal de cor $h \in \{R, G, B\}$, calcule os centróides c_i^h de cada agrupamento i , de acordo com a equação (5):

$$c_i^h = \frac{\sum_{q=1}^N U(q, i) I(q)^h}{\sum_{q=1}^N U(q, i)} \quad (5)$$

4. Recalcule os graus de pertinência entre cada *pixel* da imagem e cada agrupamento i , onde $\|I(q) - c_i\| = (I(q) - c_i)^T (I(q) - c_i)$ é a distância Euclidiana entre o q -ésimo *pixel* da imagem I e o centróide c_i :

$$U(q, i) = \left[\sum_{j=1}^C \left(\frac{\|I(q) - c_i\|}{\|I(q) - c_j\|} \right)^{\frac{2}{m-1}} \right]^{-1} \sum_{q=1}^N U(q, i)^m \|I(q) - c_i\|^2 \quad (6)$$

5. Calcule a função Objetivo J^{n+1} segundo a equação (7):

$$J^{n+1} = \sum_{q=1}^N \sum_{i=1}^C U(q, i)^m \|I(q) - c_i\|^2 \quad (7)$$

6. Com a finalidade de verificar a convergência do método, calcule $\partial = J^{n+1} - J^n$ e verifique se $\partial \leq \epsilon$. Se a condição for respeitada, finalize a execução do algoritmo. Senão, retorne ao Passo 3.

Além de ser computacionalmente mais caro que o K-Means, um ponto fraco do método *Fuzzy C-Means* se refere ao caso de um *pixel* possuir graus de pertinência quase idênticos entre duas ou mais classes, como por exemplo, 0.51 e 0.49 para duas classes 1 e 2, respectivamente. Percebe-se um alto índice de confusão, pois o *pixel* pode pertencer quase que igualmente a qualquer uma das duas classes, embora o método classificaria o *pixel* como pertence à classe 1.

3. Critérios para Validação de Agrupamento

Nesta seção, são apresentados dois critérios relativos para validade de agrupamentos. A finalidade deste critério é verificar a qualidade de uma partição gerada pelo algoritmo de agrupamento. Neste trabalho, utilizou-se os critérios de Silhueta Simplificado (CSS) [Hruschka et al. 2004] [Rousseeuw 1987] e o critério Silhueta Fuzzy (CSF) [Campello e Hruschka 2006] para avaliar os resultados do algoritmos K-Means e Fuzzy C-Means, respectivamente.

O critério de silhueta também é útil no processo de obtenção do número ideal de grupos a serem gerados pelos algoritmos. Neste caso, executa-se o algoritmo de agrupamento sobre uma imagem para diversas quantidades de agrupamento e escolhe-se aquela quantidade que possuir a maior silhueta. Assim, o objetivo é escolher uma quantidade de agrupamentos cuja partição gerada maximize a distância entre os grupos e minimize a distância entre os *pixels* de cada grupo.

3.1. Silhueta Simplificada

O Critério de Silhueta Simplificado é utilizado no algoritmo K-Means e é dado por

$$CS = \frac{1}{N} \sum_{q=1}^N s(q) \quad (8)$$

em que $s(q)$ é a silhueta do q -ésimo *pixel* da imagem, que é obtido como

$$s(q) = \frac{b(q) - a(q)}{\max\{a(q), b(q)\}} \quad (9)$$

onde $a(q)$ é a dissimilaridade do q -ésimo *pixel* da imagem ao centróide do agrupamento ao qual está associado e $b(q)$ é a dissimilaridade do q -ésimo *pixel* ao centróide do agrupamento mais próximo.

O objetivo desta silhueta é encontrar uma partição tal que (9) seja maximizado. Percebe-se que $-1 \leq s(q) \leq 1$ [Rousseeuw 1987], logo, quanto menor for o valor de $a(q)$ e maior for o valor de $b(q)$, mais próximo de 1 é $s(q)$, o que implica que o agrupamento dos dados determinado pelo algoritmo é apropriado.

3.2. Silhueta Fuzzy

Por sua vez, o Critério de Silhueta Fuzzy é calculado como

$$CSF = \frac{1}{N} \frac{\sum_{q=1}^N (b'(q) - a'(q))^\alpha s(q)}{\sum_{q=1}^N (b'(q) - a'(q))^\alpha} \quad (10)$$

onde $\alpha \geq 0$ e $a'(q)$ é o grau de pertinência do q -ésimo *pixel* da imagem ao centróide do agrupamento ao qual está associado e $b'(q)$ é o grau de pertinência q -ésimo *pixel* em relação ao centróide do agrupamento mais semelhante. Na silhueta fuzzy, $s(q)$ é calculado de maneira equivalente a (9).

4. Resultados

Os dois métodos foram testados utilizando-se 65 imagens coloridas selecionadas aleatoriamente da base de dados Berkeley Segmentation Dataset [Ber], que disponibiliza imagens do cotidiano. As imagens utilizadas para processamento têm 481×321 *pixels*. As Figuras 1, 2, 4 e 3 ilustram exemplos do processamento de algumas das imagens da referida base para 3, 4, 3 e 5 agrupamentos, respectivamente.




Figura 1. Comparação de resultados entre as técnicas para 3 agrupamentos: (a) Imagem original; (b) K-Means; (c) Fuzzy C-Means.

Observa-se que nas Figuras 1, 2 e 3, quando a imagem possui grupos bem separados, a abordagem *hard* do K-Means é superior em relação ao Fuzzy C-Means. Este último pode ser útil quando os agrupamentos estão sobrepostos, o que dificulta a obtenção de dados estatísticos, exemplificado na Figura 4, onde percebe-se uma maior preservação dos detalhes e bordas.




Figura 2. Comparação de resultados entre as técnicas para 4 agrupamentos: (a) Imagem original; (b) K-Means; (c) Fuzzy C-Means.

Baseado nos resultados das Figuras 1, 2 e 4, e principalmente da 3, verifica-se que o Fuzzy C-Means é mais sensível aos detalhes e as pequenas variações de intensidade da imagem comparado ao K-Means. Isto pode ser explicado pela natureza de uma abordagem *soft*, onde um *pixel* pouco semelhante, ou até mesmo ruídos, podem ter um grau de




Figura 3. Comparação de resultados entre as técnicas para 5 agrupamentos: (a) Imagem original; (b) K-Means; (c) Fuzzy C-Means.

relação com os agrupamentos.

Os critérios de Silhueta Simplificada e Silhueta Fuzzy foram aplicados na Figura 1(a). Foram gerados valores de silhuetas para um número de agrupamentos que variou de 2 à 8 e os valores do CSS e CSF são ilustrados na Figura 5. Pode-se perceber que o melhor agrupamento dos dados foi obtido com para 2 agrupamentos em ambos os casos e a pior partição foi gerada com 6 e 8 agrupamentos no K-Means (linha vermelha no Gráfico 5) e no Fuzzy C-Means (linha azul), respectivamente. Utilizou-se $\alpha = 1$ no experimento da Silhueta Fuzzy.




Figura 4. Comparação de resultados entre as técnicas para 3 agrupamentos: (a) Imagem original; (b) K-Means; (c) Fuzzy C-Means.

Em relação à complexidade computacional, o K-Means é da ordem $O(3NK)$ por iteração de tempo, onde 3 é a quantidade de canais de cores utilizados, sendo, portanto, linear relativo ao número de *pixels* da imagem. Por realizar cálculos mais complexos, o Fuzzy C-Means tem uma performance mais pobre comparada à performance do K-Means, apesar de funcionar de maneira semelhante.

5. Considerações Finais

Este artigo descreveu em detalhes duas técnicas de agrupamento que podem ser utilizadas para a segmentação de imagens do cotidiano: K-Means e Fuzzy C-Means. Foi mostrado que o funcionamento dos dois algoritmos é parecido, no entanto, atenta-se ao fato de que o K-Means consiste de uma abordagem *hard*, enquanto que, o Fuzzy C-Means possui uma abordagem *soft*.

Os algoritmos K-Means e Fuzzy C-Means se mostraram flexíveis e habilitados




Figura 5. Comparação entre Critério de Validação Silhueta Simplificada e Silhueta Fuzzy: (a) Silhueta Simplificada (CSS) marcado pela linha vermelho; (b) Silhueta Fuzzy (CSF) marcado pela linha azul.

para tratarem imagens de qualquer contexto, pois cada imagem é processada sem depender de resultados anteriores. Para as imagens naturais, que variam muito na intensidade e na forma, o primeiro foi mais eficaz em casos onde a imagem tem agrupamentos bem definidos, apesar de que o segundo pode ser bastante útil em imagens onde os agrupamentos tendem a se sobreporem no espaço de características.

Uma importante consideração a se fazer é que melhores resultados podem ser obtidos utilizando-se um valor ideal para o número de agrupamentos a serem encontrados para cada imagem e inicializando os centros de maneira apropriada.

Referências

- The Berkeley Segmentation Dataset and Benchmark*. UC Berkeley EECS, <http://www.eecs.berkeley.edu/research/projects/cs/vision/bsds/> edition.
- Campello, R. J. G. B. e Hruschka, E. R. (2006). A fuzzy extension of the silhouette width criterion for cluster analysis. *Fuzzy Sets and Systems*, 157:2858 – 2875.
- Duda, R. O., Hart, P. E., e Stork, D. G. (2000). *Pattern Classification*. Wiley-Interscience, 2nd edition.
- Hruschka, E. R., de Castro, L. N., e Campello, R. J. G. B. (2004). Evolutionary algorithms for clustering gene-expression data. *Proc. IEEE International Conference on Data Mining 2004 ICDM'04*, 157:403 – 406.
- Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Proc. IEEE International Conference on Data Mining 2004 ICDM'04*, 20:53 – 65.
- Samma, A. S. B. e Salam, R. A. (2009). Adaptation of k-means algorithm for image segmentation. In *Proceedings of World Academy of Science, Engineering and Technology*, pages 58–62. Spring.
- Sato-Ilic, M. e Jain, L. C. (2006). Evaluation of fuzzy clustering. *Inovations on Fuzzy Clustering*, 205:105 – 123.
- Tan, P. N., Steinbach, M., e V.Kumar (2006). *Introduction to Data Mining*. Pearson, 1st edition.