

# Um Método Híbrido Fuzzy-Swarm-Clustering para Segmentação de MRI

Emilly Pereira Alves  
NPT - POLI  
Universidade de Pernambuco  
Email: epa@poli.br

Felipe Alberto B. S. Ferreira  
Departamento de Eletrônica e Sistemas  
Universidade Federal de Pernambuco  
Email: felipe.bsferreira@ufpe.br

Márcio José de Carvalho Lima  
NPT - POLI  
Universidade de Pernambuco  
Email: marcio.lima@poli.br

**Resumo**—O processo de segmentação de Imagens por Ressonância Magnética (*Magnetic Resonance Imaging - MRI*) se destaca ao atuar na detecção das diferentes regiões do cérebro, sendo os métodos por clusterização comumente utilizados na literatura. A fim de otimizar as técnicas já existentes, o presente trabalho propõe uma técnica híbrida dos algoritmos *Fuzzy C-Means (FCM)* e o *Particle Swarm Optimization (PSO)*, denotada *Hybrid-Fuzzy C-Means and Particle Swarm Optimization (H-FCMPSO)*. Com o propósito de avaliar o desempenho dos algoritmos foram utilizadas imagens sintéticas e simulações de MRI do cérebro. O desempenho foi mensurado em termos de *Peak Signal-to-noise Ratio (PSNR)*, *Segmentation Accuracy (SA)* e *Mean Squared Error (MSE)*.

**Abstract**—The segmentation process in Magnetic Resonance Imaging (MRI) stands out when it acts in the detection of different regions of the brain. Among the used techniques, clustering segmentation methods have been commonly used in the literature. In order to optimize the already existing techniques, this paper proposes a hybrid technique with Fuzzy C-Means and Particle Swarm Optimization algorithms. With the purpose of evaluating the algorithms' performance, synthetic images and brain simulated MRI were used. The performance was measured in terms of Peak Signal-to-noise Ratio (PSNR), Segmentation Accuracy (SA) and Mean Squared Error (MSE).

## I. INTRODUÇÃO

Imagens digitais são comumente utilizadas na investigação e detecção de diversas patologias no cenário médico. Aplicações clínicas tipicamente requerem a segmentação das imagens para que diferentes partes anatômicas ou tecidos biológicos sejam identificáveis [1]. Para MRI do cérebro, a segmentação desempenha um importante papel, uma vez que a partir dela é feita a classificação de matéria branca, substância cinzenta, líquido cefalorraquidiano (LCR) e tumores, por exemplo [2]. A segmentação dessas imagens é, geralmente, realizada manual ou semi-manualmente por radiologistas e/ou médicos especialistas. Este processo é, normalmente, demorado e a intervenção humana pode acarretar em diferentes diagnósticos [1], [3]. Por este motivo, técnicas computacionais vêm sendo aplicadas na segmentação de imagens médicas.

Técnicas de clusterização, que tem por objetivo estudar e agrupar amostras conforme sua similaridade, vêm sendo utilizadas para segmentação de imagens médicas. Dentre estas, o algoritmo *Fuzzy C-Means (FCM)* [4] é um dos mais utilizados devido a sua robustez contra a homogeneidade encontrada nas imagens médicas [5]. O desempenho do método está fortemente relacionado com o processo de inicialização do

algoritmo, isto é, dependendo dos valores inicialmente atribuídos o algoritmo pode facilmente ficar “preso” em um mínimo local. Outras versões do FCM vêm sendo apresentadas na literatura. Benaichouche *et.al* propuseram em 2013 [6] uma versão aprimorada do FCM, cuja inicialização dos centroides é realizada pelo algoritmo de enxames denominado *Particle Swarm Optimization (PSO)* [7]. Em seu método, após a inicialização pelo PSO, o tradicional FCM é executado utilizando como métrica de avaliação a distância de Mahalanobis.

No presente trabalho é proposto um novo método de segmentação por clusterização baseado na junção do FCM com uma técnica de otimização por enxame, particularmente o PSO, denominado *Hybrid - Fuzzy C-Means and Particle Swarm Optimization (H-FCMPSO)*. Diferente de [6], que utiliza o PSO apenas na para inicializar o primeiro conjunto de centroides, o H-FCMPSO utiliza as características de otimização do PSO em todas as etapas do tradicional FCM, a fim de manter a característica de convergência do FCM e reduzir o problema de mínimo local pela capacidade de exploração do PSO.

O trabalho encontra-se organizado da seguinte forma: Na Seção II são apresentados dois algoritmos clássicos de segmentação baseados em clusterização: *K-Means* e FCM. A Seção III apresenta o método proposto, os materiais e métodos utilizados são apresentados na Seção IV e os resultados experimentais e discussão são retratados na Seção V. Por fim, a Seção VI apresenta a conclusão e trabalhos futuros.

## II. SEGMENTAÇÃO POR CLUSTERIZAÇÃO

O processo de segmentação de imagens é definido como uma técnica que particiona uma imagem em diferentes regiões com alto grau de similaridade. Algumas categorias de técnicas de segmentação são definidas, como por exemplo limiarização, detecção de bordas e crescimento de região [8]. As técnicas de clusterização consistem no agrupamento de amostras com base em suas características, fazendo com que amostras semelhantes pertençam a um mesmo *cluster* (grupo). O centro de cada *cluster* é denominado centroide.

### A. *K-Means*

O algoritmo de clusterização *K-Means* [9] é um processo iterativo, cujas etapas são: inicialização, particionamento, avaliação do critério de parada e cálculo dos centroides. Primei-

ramente, a quantidade de amostras é definida e os centroides são inicializados. Durante o particionamento, para cada amostra, calcula-se a distância Euclidiana entre ela e cada um dos centroides. A amostra passa a pertencer ao *cluster*, cuja distância para o respectivo centroide é a menor entre as demais. O algoritmo é finalizado quando a distorção atinge um limiar  $\varepsilon$  previamente estabelecido, conforme

$$\frac{D^{(t-1)} - D^{(t)}}{D^{(t)}} \leq \varepsilon, \quad (1)$$

em que  $D^{(t-1)}$  representa a distorção da iteração anterior e  $D^{(t)}$  é a distorção da iteração atual. A distorção, isto é, a distância total de cada amostra para o centroide de seu respectivo *cluster*, é dada por

$$D = \sum_{j=1}^N \sum_{x_i \in S_j} (x_i - c_j)^2, \quad (2)$$

em que  $N$  corresponde a quantidade de centroides,  $c_j$  é o  $j$ -ésimo centroide,  $x_i$  é a  $i$ -ésima amostra do conjunto de entrada  $\mathbf{X}$  e  $S_j$  é o conjunto de amostras  $x_i$  pertencentes ao *cluster*  $c_j$ . Caso o critério de parada não seja satisfeito, a posição de cada centroide é atualizada com a média das posições das amostras pertencentes ao seu respectivo *cluster*.

### B. Fuzzy C-Means (FCM)

O algoritmo FCM [4] é um processo iterativo similar ao *K-Means*, porém, as amostras podem pertencer a mais de um *cluster* em um mesmo instante. Isso é implementado através de um grau de pertencimento entre as amostras e cada centroide, definido por

$$\mu_{ij} = \frac{1}{\sum_{m=1}^N \left( \frac{(x_i - c_j)^2}{(x_i - c_m)^{\frac{2}{k-1}}} \right)}, \quad 1 < k < \infty, \quad (3)$$

em que  $\mu_{ij}$  representa o grau de pertencimento da amostra  $x_i$  ao centroide  $c_j$  e  $k \in \mathbb{R}$  é uma constante. Após o cálculo do grau de pertencimento os centroides são atualizados conforme

$$c_j = \frac{\sum_{i=1}^M \mu_{ij}^k x_i}{\sum_{i=1}^M \mu_{ij}^k}, \quad 0 \leq j < N. \quad (4)$$

O algoritmo é finalizado caso a condição de parada definida na Eq. (1), seja satisfeita. A distorção total a ser minimizada pelo FCM é dada por

$$D = \sum_{j=1}^N \sum_{i=1}^M \mu_{ij}^k (x_i - c_j)^2, \quad (5)$$

em que  $M$  corresponde ao número total de amostras.

### III. MÉTODO PROPOSTO

A proposta deste trabalho é um algoritmo híbrido do FCM com PSO, denominado H-FCMPSO. O principal objetivo é manter a robustez do FCM contra a homogeneidade naturalmente presente em MRI, e diminuir o problema de mínimo local, inerente ao FCM, utilizando as características de exploração do PSO.

O PSO [7] é um algoritmo de otimização baseado em inteligência de enxame, cuja metáfora refere-se a uma revoada de pássaros durante o vôo. Algoritmos que usam o PSO como referência, têm como objetivo encontrar a melhor região no espaço de busca, baseada na experiência do enxame.

No H-FCMPSO, cada partícula  $\mathbf{P}_n = \{c_0, c_1, \dots, c_N\}$ ,  $0 \leq n < L$ , representa um conjunto de centroides diferente. A cada iteração é armazenado o melhor conjunto de centroides, denominado *global best* ( $\mathbf{gbest}$ ), e para cada partícula  $\mathbf{P}_n$  é armazenado seu respectivo melhor conjunto de centroides, denominado *personal best* ( $\mathbf{pbest}_n$ ). Quanto menor a distorção, dada pela Eq. (5), melhor é a posição ocupada por uma partícula. Além disso, a cada iteração, cada partícula  $\mathbf{P}_n$  é movimentada em direção ao seu respectivo  $\mathbf{pbest}_n$  e ao  $\mathbf{gbest}$  de acordo com

$$\mathbf{V}_n^{(t+1)} = \mathbf{V}_n^{(t)} + f_1 r_1 (\mathbf{pbest}_n - \mathbf{P}_n^{(t)}) + f_2 r_2 (\mathbf{gbest} - \mathbf{P}_n^{(t)}) \quad (6)$$

e

$$\mathbf{P}_n^{(t+1)} = \mathbf{P}_n^{(t)} + \mathbf{V}_n^{(t+1)}, \quad (7)$$

em que  $f_1$  e  $f_2$  são fatores pré-determinados que indicam o grau de influência da *personal best* e *global best*, respectivamente, e,  $r_1$  e  $r_2$  são fatores gerados por uma sequência pseudo-aleatória uniformemente distribuída entre  $[0, 1]$ . A seguir é apresentada a sequência de passos do algoritmo H-FCMPSO:

0. Faça  $D^{(t-1)} \leftarrow D_{\mathbf{gbest}} \leftarrow D_{\mathbf{pbest}_n} \leftarrow \infty$ ;
1. Calcule, para cada partícula  $\mathbf{P}_n^{(t)}$ , o grau de pertencimento das amostras conforme Eq. (3);
2. Atualize cada partícula  $\mathbf{P}_n^{(t)}$  conforme Eq. (4);
3. Para cada partícula  $\mathbf{P}_n^{(t)}$ ,
  - 3.1. Calcule  $D_n$  conforme Eq. (5);
  - 3.2. Se  $D_n^{(t)} < D_{\mathbf{pbest}_n}$ , então  $D_{\mathbf{pbest}_n} \leftarrow D_n^{(t)}$ ;
  - 3.3. Se  $D_n^{(t)} < D_{\mathbf{gbest}}$ , então  $D_{\mathbf{gbest}} \leftarrow D_n^{(t)}$ ;
4. Se  $\frac{D^{(t-1)} - D_{\mathbf{gbest}}}{D_{\mathbf{gbest}}} \leq \varepsilon$ , pule para o **Passo 7**;
5. Atualize cada partícula  $\mathbf{P}_n^{(t+1)}$  conforme Eq. (6) e (7);
6. Faça  $D^{(t-1)} \leftarrow D_{\mathbf{gbest}}$  e volte para o **Passo 1**;
7. Retorne o grau de pertencimento das amostras referente a partícula  $\mathbf{gbest}$ .

### IV. MATERIAIS E MÉTODOS

A fim de analisar a performance do algoritmo proposto, o presente trabalho divide-se em duas etapas: Segmentação de imagens sintéticas e segmentação simuladas de MRI. Inicialmente nas simulações foi utilizada uma imagem sintética, apresentada na Figura 1a, de  $256 \times 256$ , composta por 4 níveis de cinza. Devido ao conhecimento prévio dos níveis de cinza que compõem cada segmento, foram gerados os *ground truths* para cada intensidade de cinza, apresentados nas Figuras 1b, 1c, 1d e 1e.

Posteriormente, o algoritmo foi avaliado quando aplicado em MRI, as quais foram obtidas da base de imagens, BrainWeb [10], cujas simulações são baseadas em um modelo




Figura 1. Imagem sintética original e segmentações manuais (*ground truths*).

anômico de cérebro normal. Neste trabalho foram utilizadas 5 imagens ( $181 \times 217$  pixels) de cérebro normais obtidas por MRI simulado, com 0%, 3%, 5%, 7% e 9% de ruído, respectivamente, todas de modalidade T1, 1mm de espessura e 0% de intensidade não-uniforme. As Figuras 2a, 2b, 2c e 2d apresentam a imagem com 0% de ruído, e os *ground truths* do LCR, substância cinzenta e matéria branca, respectivamente.



Figura 2. Imagem original obtida por MRI simulada (0% ruído) e *ground truths* das regiões consideradas.

Foram realizadas 30 simulações para cada imagem, sintética e MRI, a serem segmentadas com 4 e 5 *clusters*, respectivamente, com limiar de distorção  $\varepsilon = 0,001$ . Para o algoritmo H-FCMPSO, foram utilizadas 30 partículas e os fatores  $f_1$  e  $f_2$  foram 0,1 e 0,3, respectivamente. Para os algoritmos FCM e H-FCMPSO, atribuiu-se valor 2 para a constante  $k$ .

Com o propósito de mensurar o desempenho dos algoritmos utilizados, quanto as MRI simuladas, os 5 *clusters* correspondem as seguintes características: i) Líquido Cefalorraquidiano (LCR), ii) Matéria Branca, iii) Substância Cinzenta, iv) *Background* e v) Caixa craniana e outros tecidos, sendo i, ii e iii as áreas de interesse analisadas neste trabalho.

As técnicas foram avaliadas segundo a qualidade das imagens segmentadas comparadas aos seus respectivos *ground truths*, pelos métodos: *Peak Signal-to-noise Ratio* (PSNR), *Mean Squared Error* (MSE) e *Segmentation Accuracy* (SA).

## V. RESULTADOS

A Tabela I apresenta os valores médios de MSE e SA obtidos nas simulações das imagens sintéticas. Em termos de MSE, para o *cluster 1*, os métodos *K-Means* e H-FCMPSO obtiveram valor zero, isto é, as imagens são iguais aos seus respectivos *ground truths*. Quanto aos outros *clusters*, o H-FCMPSO apresenta superioridade em relação aos demais métodos. É possível obter erros próximos a zero, como por exemplo, 0,003 e 0,006, nos *clusters 4* e *2*, respectivamente. O H-FCMPSO possui superioridade em até 0,223 quando comparado ao FCM, e 0,065 quando comparado ao *K-Means*. Por conseguinte, o *K-Means* obtém melhor desempenho em relação ao FCM, com valores até 0,208 menores.

Em relação a SA, para o *cluster 1*, os algoritmos *K-Means* e H-FCMPSO apresentam 100% de acurácia, seguido do FCM que possuiu a média de 77,36% de pixels segmentados corretamente. Nos demais *clusters* o H-FCMPSO é superior. Por exemplo, para o *cluster 2*, o H-FCMPSO possui uma

acurácia 20,16% superior a obtida pelo FCM. Ademais, o *K-Means* se destaca em relação ao FCM, obtendo valores de acurácia superiores em até 18,99%.

Tabela I  
SA(%) E MSE PARA IMAGENS SINTÉTICAS, OBTIDOS PELOS ALGORITMOS *K-Means* (I), FCM (II) E H-FCMPSO (III).

Região	Método					
	MSE			SA(%)		
	I	II	III	I	II	III
Cluster 1	<b>0,000</b>	0,226	<b>0,000</b>	<b>100,00</b>	77,36	<b>100,00</b>
Cluster 2	0,018	0,208	<b>0,006</b>	98,17	79,19	<b>99,35</b>
Cluster 3	0,068	0,087	<b>0,009</b>	93,16	91,32	<b>99,09</b>
Cluster 4	0,061	0,079	<b>0,003</b>	93,94	92,09	<b>99,74</b>

Os valores médios de PSNR e SA, para MRI sintéticas, são apresentados na Tabela II, classificados de acordo com o percentual de ruído, região segmentada e algoritmo. As regiões apresentadas são LCR, substância cinzenta (S. Cinz.) e matéria branca (Mat. Br.).

Em termos de PSNR, o H-FCMPSO se destaca entre as demais técnicas para as imagens com 7% e 9% de ruído, em todos os segmentos. Com este algoritmo é possível obter um ganho de 0,352 dB se comparado ao *K-Means* e 0,365 dB em relação ao FCM, no que se refere a segmentação da matéria branca com 9% de ruído. Com 7% de ruído, o método proposto possui ganho de 0,377 dB e 0,126 dB se comparado ao *K-Means* e FCM, respectivamente, para substância cinzenta. Para imagens sem ruído, o FCM se destaca dos outros métodos, apresentando ganho de até 0,605 dB para substância cinzenta e 0,236 dB para matéria branca. Por conseguinte, ainda em imagens sem ruído, o *K-Means* apresenta, na segmentação do LCR, um ganho de 0,230 dB e 0,147 dB em relação ao FCM e H-FCMPSO, respectivamente. Considerando as imagens com 5% de ruído, o H-FCMPSO se destaca nas regiões do LCR e matéria branca, com ganhos de até 0,210 dB e 0,190 dB, respectivamente. Quanto a região de substância cinzenta o melhor desempenho foi do FCM, com ganho de até 0,169 dB em relação aos demais. Em imagens com 3% de ruído, o algoritmo *K-Means* se destaca em duas regiões, matéria branca e substância cinzenta, com ganho de até 0,4 dB. Nestas imagens o H-FCMPSO obteve superioridade na região de LCR, apresentando ganho em até 0,294 dB, comparado aos demais.

Em termos de SA, o H-FCMPSO apresenta uma superioridade sobre as demais técnicas de até 1,03% para imagens com 9% de ruído e 1,24% para imagens com 7% de ruído. Para as imagens com 5% de ruído, o H-FCMPSO apresenta um melhor desempenho apenas na região do LCR, com 0,33% de aumento em comparação aos demais algoritmos. Nestas imagens, o *K-Means* se destaca no resultado da segmentação da região de matéria branca, com ganho de até 0,46%, e o FCM apresenta melhor resultado na região de substância cinzenta, com superioridade de até 1% em relação as demais. Nas imagens com 3% de ruído, o *K-Means* apresenta um melhor desempenho em duas regiões, matéria branca e substância cinzenta, com valores superiores em até 0,12% e 0,70%, respectivamente. Em seguida, o H-FCMPSO obtém, na

região do LCR, superioridade de até 0,50% comparado com os demais.

Tabela II

PSNR (dB) E SA (%) PARA IMAGENS COM RUÍDO DE 0% A 9%, OBTIDOS PELAS TÉCNICAS *K-Means* (I), FCM (II) E H-FCMPSO (III).

Ruído	Região	Método					
		PSNR (dB)			SA (%)		
		I	II	III	I	II	III
0%	LCR	<b>11,001</b>	10,771	10,855	<b>92,11</b>	91,62	91,77
	S. Cinz.	10,976	<b>11,371</b>	10,767	91,87	<b>92,70</b>	91,37
	Mat. Br.	13,703	<b>13,853</b>	13,616	95,65	<b>95,87</b>	94,97
3%	LCR	10,937	10,972	<b>11,231</b>	91,94	92,00	<b>92,44</b>
	S. Cinz.	<b>11,121</b>	10,948	10,722	<b>92,27</b>	91,93	91,57
	Mat. Br.	<b>13,491</b>	13,360	13,115	<b>95,49</b>	95,37	95,40
5%	LCR	11,058	11,059	<b>11,267</b>	92,16	92,16	<b>92,50</b>
	S. Cinz.	9,811	<b>9,842</b>	9,673	89,19	<b>89,54</b>	88,54
	Mat. Br.	11,624	11,745	<b>11,814</b>	<b>93,39</b>	93,04	92,93
7%	LCR	10,917	10,882	<b>11,054</b>	91,90	91,84	<b>92,14</b>
	S. Cinz.	8,259	8,510	<b>8,636</b>	84,90	85,72	<b>86,13</b>
	Mat. Br.	10,571	10,535	<b>10,660</b>	91,01	91,11	<b>91,26</b>
9%	LCR	10,186	10,152	<b>10,309</b>	90,41	90,34	<b>90,65</b>
	S. Cinz.	8,289	8,186	<b>8,475</b>	85,10	84,70	<b>85,74</b>
	Mat. Br.	9,396	9,383	<b>9,749</b>	88,40	88,42	<b>89,32</b>

A Figura 3 apresenta os *ground truth* do LCR, da matéria branca e da substância cinzenta, foco deste trabalho, assim como as imagens obtidas nas simulações realizadas para cada algoritmo.




Figura 3. *Ground truths* de cada região considerada e respectivos resultados de segmentação obtidos pelos algoritmos *K-Means*, FCM e H-FCMPSO.

## VI. CONCLUSÃO

Neste trabalho, é introduzido um novo algoritmo de segmentação por clusterização baseado em técnicas de enxame, denominado H-FCMPSO, objetivando otimizar as técnicas presentes na literatura, mais precisamente, os algoritmos FCM e PSO. A técnica proposta levou a melhores desempenhos, em termos de SA e PSNR, para MRI simuladas com 7% e 9% de

ruído, em todas as regiões de interesse. Ainda se tratando de MRI, o H-FCMPSO se destacou na segmentação das regiões LCR para imagens com 3% e 5% de ruído. Um resultado geral, considerando todas as imagens avaliadas, em termos de percentual que cada técnica foi superior as demais, o H-FCMPSO apresentou superioridade sobre as demais técnicas em 60% das simulações. Quanto aos algoritmos FCM e *K-Means*, estes obtiveram um empate de desempenho de 20%. Em termos de SA, os resultados se equipararam, na maioria dos casos, aos de PSNR, cujo melhor desempenho foi do H-FCMPSO, com superioridade de 26,67% e 33,33% em relação ao *K-Means* e FCM, respectivamente. Nos testes realizados com imagens sintéticas, para o *cluster* 1, houve um empate no desempenho das técnicas *K-Means* e H-FCMPSO. Entretanto, nos demais *clusters*, o H-FCMPSO obteve uma superioridade sistemática quando comparado aos outros métodos.

Como trabalhos futuros, será feita a avaliação no que concerne aos custos computacionais dos algoritmos. Além disso, pode-se considerar a aplicação de novas técnicas de enxame e aplicações de filtros a fim de melhorar a qualidade da imagem segmentada.

## AGRADECIMENTOS

Este trabalho recebeu apoio parcial da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), projeto APQ 5030418.

## REFERÊNCIAS

- [1] A. Demirhan and İ. Güler, "Combining stationary wavelet transform and self-organizing maps for brain mr image segmentation," *Engineering Applications of Artificial Intelligence*, vol. 24, no. 2, pp. 358–367, 2011.
- [2] H. Hooda, O. P. Verma, and T. Singhal, "Brain tumor segmentation: A performance analysis using k-means, fuzzy c-means and region growing algorithm," in *Advanced Communication Control and Computing Technologies (ICACCCT), 2014 International Conference on*. IEEE, 2014, pp. 1621–1626.
- [3] S. K. Adhikari, J. K. Sing, D. K. Basu, and M. Nasipuri, "Conditional spatial fuzzy c-means clustering algorithm for segmentation of mri images," *Applied Soft Computing*, vol. 34, pp. 758–769, 2015.
- [4] J. C. Bezdek, R. Ehrlich, and W. Full, "Fcm: The fuzzy c-means clustering algorithm," *Computers & Geosciences*, vol. 10, no. 2-3, pp. 191–203, 1984.
- [5] J. C. Dunn, "A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters," 1973.
- [6] A. N. Benaichouche, H. Oulhadj, and P. Siarry, "Improved spatial fuzzy c-means clustering for image segmentation using pso initialization, mahalanobis distance and post-segmentation correction," *Digital Signal Processing*, vol. 23, no. 5, pp. 1390–1400, 2013.
- [7] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," in *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on*. IEEE, 1995, pp. 39–43.
- [8] R. C. Gonzalez and R. E. Woods, *Digital image processing*. New Jersey: Prentice Hall, 2008.
- [9] J. MacQueen *et al.*, "Some methods for classification and analysis of multivariate observations," in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, vol. 1, no. 14. Oakland, CA, USA, 1967, pp. 281–297.
- [10] C. A. Cocosco, V. Kollokian, R. K.-S. Kwan, G. B. Pike, and A. C. Evans, "Brainweb: Online interface to a 3d mri simulated brain database," in *NeuroImage*. Citeseer, 1997.