

Modelo Estatístico para a Determinação do Número Ótimo de Iterações do Filtro de Difusão Anisotrópica Aplicado à Redução de Ruído de Imagens de Ressonância Magnética do Cérebro

Yuri Saito ¹

Ricardo J. Ferrari ^{2,*}

Jefferson Teixeira ¹

Andre P.L.F. de Carvalho ¹

Paulo M. de Azevedo Marques ³

Antonio C. dos Santos ³

Resumo: Apesar do grande sucesso dos filtros de difusão anisotrópica na redução de ruídos de imagens médicas, uma limitação dessa abordagem iterativa é a determinação automática do número correto de iterações do algoritmo, visto que um número grande de iterações pode causar um borramento excessivo das bordas entre as estruturas anatômicas, enquanto um número pequeno pode não ser suficiente para remover completamente o ruído da imagem. Portanto, este trabalho propõe um modelo estatístico para a determinação automática do número ótimo de iterações do filtro de difusão anisotrópica aplicado à redução de ruído de imagens médicas. O modelo é determinado “off-line” por meio da maximização do índice de similaridade estrutural, o qual é usado neste trabalho como uma função objetivo para avaliar quantitativamente a qualidade das imagens resultantes após cada iteração do filtro. Após a determinação dos parâmetros do modelo, o número ótimo de iterações do algoritmo necessário para remover o ruído da imagem e, ao mesmo tempo preservar as bordas entre as estruturas anatômicas, é facilmente obtido. Resultados aplicados às imagens 3D de ressonância magnética do cérebro são apresentados para ilustrar a eficácia do método proposto.

¹Instituto de Ciências Matemáticas e de Computação (ICMC)
Universidade de São Paulo, São Carlos, SP, Brasil

²Departamento de Computação (DC)
Universidade Federal de São Carlos (UFSCar)
Rod. Washington Luís, Km 235 - Caixa Postal 676 - 13565-905, São Carlos, SP, Brasil
{*rferrari@dc.ufscar.br}

³Centro de Ciências das Imagens e Física Médica (CCIFM)
Departamento de Clínica Médica da Faculdade de Medicina de Ribeirão Preto (FMRP)
Universidade de São Paulo, Ribeirão Preto, SP, Brasil

Abstract: Despite the great success of the anisotropic diffusion filters applied to medical image denoising, one limitation of this iterative approach is the automatic determination of the correct number of iterations of the algorithm since a large number of iterations can cause an excessive blurring of the edges of the anatomical structures, while a small number may not be enough to completely remove the noise from an image. Therefore, this work proposes a statistical model to automatically determine the optimum number of iterations of the anisotropic diffusion filter applied to medical image denoising. The model is determined off-line by means of the maximization of the structural similarity index, which is used in this work as an objective function for quantitative quality assessment of the resulting images after each filter iteration. After determining the model parameters, the optimum number of algorithm iterations required to remove the image noise, while preserving all important edges between the anatomical structures, is easily obtained. Results of the proposed method applied to 3D magnetic resonance images of the human brain are presented to illustrate the efficiency of the proposed method.

1 Introdução

A redução de ruído é uma etapa muito importante em sistemas computadorizados usados para a segmentação de imagens médicas. Apesar do grande número de técnicas para a redução de ruído de imagens apresentadas na literatura, em geral, as que apresentam os maiores índices de relação sinal-ruído de pico (“Peak Signal-to-Noise Ratio - PSNR”) podem ser classificadas em dois grupos principais: (I) técnicas baseadas em Análise Harmônica Computacional; por exemplo, as baseadas na transformada wavelets e Fourier [1, 2] e (II) técnicas baseadas em equações diferenciais parciais (“Partial Differential Equations - PDE”); como os filtros de difusão anisotrópica [3, 4, 5].

Embora algumas técnicas relacionadas ao grupo (I) tenham se mostrado bastante promissoras quando aplicadas à redução de ruídos de imagens médicas [6, 7], em geral, elas quase sempre introduzem algum tipo de artefato nas imagens - o que é um grande impedimento para o seu uso prático em imagens médicas [8]. Embora esse problema não ocorra com os filtros de difusão anisotrópica (“Anisotropic Diffusion Filter - ADF”) propostos inicialmente por Perona & Malik [4], uma grande limitação dessa outra abordagem iterativa é a determinação correta do número de iterações do algoritmo, visto que um número grande de iterações pode causar um borramento excessivo das bordas entre as estruturas anatômicas, enquanto um número pequeno pode não ser suficiente para a remoção completa do ruído da imagem. Em [9], os autores investigaram o relacionamento entre o tempo de parada do processo evolutivo do algoritmo de difusão anisotrópica e o nível de ruído e, com base nesse estudo, um novo modelo de PDE foi proposto. Embora os autores afirmem que o método é suficientemente robusto para a redução de qualquer nível de ruído da imagem, algumas imagens apresentadas por eles como ilustração do método proposto apresentam artefatos nitidamente visíveis próximos às bordas dos objetos, o que pode comprometer o seu uso em aplicações médicas.

Neste trabalho um modelo estatístico é proposto para a determinação automática do número ótimo de iterações para o ADF aplicado na redução de ruído de imagens de Ressonância Magnética (RM) do cérebro. O modelo proposto é determinado “off-line” por meio da maximização do índice de similaridade estrutural (“Structural SIMilarity - SSIM”) [10], usado aqui como função objetivo para avaliar quantitativamente a qualidade da imagem após cada iteração do filtro. Após a determinação dos parâmetros do modelo estatístico por meio de imagens simuladas de RM obtidas do projeto “BrainWeb” [11], o número ótimo de iterações necessárias para remover o ruído de uma imagem e, ao mesmo tempo, preservar as bordas entre as estruturas anatômicas é facilmente obtido. Cabe ressaltar que nenhuma modificação é realizada diretamente no ADF, garantindo-se assim que nenhum artefato será criado ou inserido nas imagens processadas para a redução do ruído.

Esse trabalho é organizado da seguinte maneira. Na Seção 2 são apresentas informa-

ções a respeito da base de imagens utilizada, uma breve revisão teórica da técnica de difusão anisotrópica e do índice SSIM, uma discussão sobre os tipos de ruídos que afetam as imagens de RM e, a formulação do modelo estatístico proposto para a determinação do número ótimo de iterações do ADF. Resultados e discussões são apresentados na Seção 3, seguido das conclusões e considerações finais na Seção 4.

2 Materiais e Métodos

2.1 Banco de Imagens

Neste trabalho foram utilizadas imagens simuladas tridimensionais (3D) de RM do cérebro, de contraste T1-ponderado, obtidas do projeto “BrainWeb” [11]. As imagens possuem as seguintes características: matriz de aquisição de tamanho $181 \times 217 \times 181$, dimensão do pixel no plano igual a $1 \times 1 \text{ mm}^2$, espessura das fatias de 1 mm e profundidade de 12 bits. Todas as imagens foram obtidas inicialmente sem ruído e sem o efeito de heterogeneidade da intensidade dos níveis de cinza. Posteriormente, as imagens foram corrompidas por ruído do tipo Riciano por meio de um programa escrito na linguagem de programação C++, que possui um parâmetro de entrada κ que corresponde a um percentual de ruído escalonado a partir do valor máximo da intensidade de cinza da imagem de RM.

2.2 Filtro de Difusão Anisotrópica

As técnicas de difusão anisotrópica simulam, por meio do uso da equação de difusão do calor, o processo que cria um modelo do tipo espaço-escala, onde uma imagem gera uma família parametrizada de sucessivas imagens borradas. Perona e Malik [4] formularam a equação de difusão anisotrópica discreta como:

$$I_s^{t+1} = I_s^t + \frac{\lambda}{|\eta_s|} \sum_{p \in \eta_s} g(\nabla I_{s,p}) \nabla I_{s,p}, \quad (1)$$

onde, I_s^t corresponde a imagem discretizada e ∇I é o gradiente da imagem. A função $g(\cdot)$ é chamada de parada-na-aresta (“edge-stopping”) e o parâmetro t refere-se ao número de iterações. A constante $\lambda \in \mathbb{R}$, com $\lambda > 0$, corresponde à taxa de difusão e η_s define a vizinhança de um voxel na posição espacial $s = (x, y, z)$. O gradiente da imagem é calculado como:

$$\nabla I_{s,p} = I_p - I_s^t, \quad (2)$$

onde $p \in \eta_s$ representa um voxel da vizinhança η_s . O uso da direção do gradiente permite

o borramento local apenas na direção paralela às bordas da imagem, o que faz com que as bordas sejam preservadas.

2.3 Filtro de Difusão Anisotrópica Robusta

Embora a técnica de difusão anisotrópica introduzida por Perona e Malik [4] seja amplamente utilizada para a segmentação de imagens, ela possui uma desvantagem que é o inevitável borramento contínuo das bordas da imagem, caso o número de iterações continue a crescer indefinidamente. A fim de minimizar esse problema, Black *et al.* [12] propuseram uma nova função parada-na-aresta $\psi(\cdot)$ baseada em estatística robusta, e nomearam essa nova técnica como filtro de Difusão Anisotrópica Robusto (“Robust Anisotropic Diffusion Filter - RADF”). A nova função $\psi(\cdot)$ proposta por Black *et al.* é a função “Tukey’s biweight”, definida como:

$$\psi(\nabla I, \sigma) = \begin{cases} \nabla I \left[1 - \left(\frac{|\nabla I|}{\sigma} \right)^2 \right]^2 & , \text{ se } |\nabla I| \leq \sigma \\ 0 & , \text{ caso contrário} \end{cases} \quad (3)$$

onde $\sigma = \delta \cdot \sigma_\epsilon$ é chamado de parâmetro de escala de RADF e σ_ϵ é o parâmetro de escala robusto da imagem. O fator de correção δ varia de acordo com o tipo de função parada-na-aresta e no caso da função “Tukey’s biweight” o seu valor é $\sqrt{5}$ [13]. O valor de σ controla o limite mínimo da intensidade do gradiente na imagem antes dessa ser considerada ruído. O valor de σ_ϵ corresponde ao desvio padrão do ruído da imagem e é calculado como:

$$\begin{aligned} \sigma_\epsilon &= 1,4826 \cdot \text{MAD}(\nabla I) \\ &= \text{median}_I[||\nabla I - \text{median}_I(||\nabla I||)||], \end{aligned} \quad (4)$$

onde MAD é o desvio absoluto da mediana (“Median of Absolute Deviation”) e a constante 1,4826 é determinada com base no fato que o desvio absoluto da mediana de uma distribuição normal de média zero e variância unitária é igual a $0,6745 = 1/1,4826$.

Apesar do RADF apresentar melhorias em relação ao ADF, esse filtro é ainda muito dependente do número de iterações, que precisa ser ajustado manualmente e de maneira *ad-hoc* para cada fim específico e para imagens com diferentes níveis de ruído toda vez que uma imagem é processada.

2.4 Estimação de Ruído em Imagens de RM

O método de aquisição de imagens de RM mais comum é o baseado na codificação-de-fase (“phase-encoding”). Nesse método, o objeto de interesse é efetivamente imageado

no domínio da frequência [14]. Os valores medidos na aquisição são valores complexos provenientes da codificação da fase e frequência dos sinais de rádio frequência. Esses valores são armazenados em um espaço de memória temporária conhecido como “k-space”, e são indicados como:

$$Y(\mu, v) = Y_{Re}(\mu, v) + iY_{Im}(\mu, v), \quad (5)$$

onde μ e v indicam as frequências horizontais e verticais, $i = \sqrt{-1}$, e $Y_{Re}(\mu, v)$ e $Y_{Im}(\mu, v)$ são os componentes reais e imaginários dos dados.

Em equipamentos de RM com campo magnético de intensidade média ou alta, os componentes $Y_{Re}(\mu, v)$ e $Y_{Im}(\mu, v)$ são corrompidos principalmente por ruído térmico (branco) Gaussiano aditivo, devido ao próprio paciente [15]. A técnica de reconstrução da imagem de RM mais comum é a que utiliza a transformada rápida inversa de Fourier (“Inverse Fast Fourier Transform - IFFT”) das medições $Y(\mu, v)$, ou seja,

$$\hat{Y}(\mu, v) = \text{IFFT}\{Y(\mu, v)\} = \hat{Y}_{Re}(\mu, v) + i\hat{Y}_{Im}(\mu, v). \quad (6)$$

Visto que a IFFT é uma transformação linear e ortogonal, ela não altera a forma funcional das distribuições dos dados complexos. A imagem de RM I usual corresponde a magnitude do sinal complexo de RM, que é calculado como

$$I = \sqrt{\hat{Y}_{Re}^2(\mu, v) + \hat{Y}_{Im}^2(\mu, v)}. \quad (7)$$

Como os componentes reais e imaginários de $\hat{Y}(\mu, v)$ correspondem a soma de variáveis aleatórias independentes e $\sqrt{\cdot}$ é uma operação matemática não-linear, a distribuição Gaussiana original dos valores de cada componente é mapeada para uma distribuição Rician [5]. Em regiões de baixa intensidade do sinal (região de fundo da imagem com baixo valor de SNR), a distribuição tende a uma distribuição Rayleigh. Por outro lado, em regiões de alta intensidade do sinal (região do objeto imageado com alto valor de SNR), ela se aproxima de uma distribuição Gaussiana [15].

Portanto, para a estimação correta do desvio padrão σ_o do ruído do objeto, pode-se utilizar tanto a região interna ao objeto com intensidade constante, onde os valores da intensidade seguem uma distribuição Gaussiana com média zero e desvio padrão σ_o , quanto a região de fundo da imagem, onde os valores da intensidade seguem uma distribuição Rayleigh com desvio padrão σ_b . Nesse último caso, um fator de correção deve ser aplicado ao valor estimado σ_b para que esse corresponda ao valor do ruído no objeto.

Por simplicidade, neste trabalho optou-se por estimar σ_b a partir da intensidade dos voxels da região de fundo da imagem e realizar a correção do ruído como:

$$\sigma_o = \frac{1}{\sqrt{\frac{4-\pi}{2}}} \cdot \sigma_b \approx 1,527 \cdot \sigma_b,$$

onde 1,527 é o fator de correção da distribuição [16]. Neste trabalho, a região de fundo da imagem foi determinada por meio da técnica de limiarização de Otsu [17]. Cabe ressaltar também que o fator de escala robusto do RADF é igual ao desvio padrão do ruído do objeto na imagem, ou seja, $\sigma_\epsilon = \sigma_o \approx 1,527\sigma_b$.

2.5 Índice de Similaridade Estrutural (SSIM)

O índice de similaridade estrutural foi proposto por Wang et al. [10] para medir a fidelidade entre duas imagens. O índice SSIM é considerado uma métrica de referência completa, o que significa que a medição da qualidade (ou fidelidade) de uma determinada imagem por meio desse índice é baseada (ou referenciada) em uma imagem inicial não-comprimida e livre de distorções e ruídos. Diferentemente dos métodos tradicionais usados para medir a qualidade de imagens, como o PSNR e o erro médio quadrático (“mean squared error - MSE”), o índice SSIM é consistente com a percepção visual humana e seu valor varia convenientemente entre 0 e 1.

Embora existam algumas variações do índice SSIM, em sua forma básica o índice SSIM local é calculado entre duas regiões locais correspondentes m e n como a composição de três medidas de similaridades entre; a similaridade de brilho $b(m, n)$, de contraste $c(m, n)$ e de estrutura $e(m, n)$ como:

$$\begin{aligned} \text{SSIM}(m, n) &= b(m, n) \cdot c(m, n) \cdot e(m, n) \\ &= \left(\frac{2\mu_m\mu_n + C_1}{\mu_m^2 + \mu_n^2 + C_1} \right) \cdot \left(\frac{2\sigma_m\sigma_n + C_2}{\sigma_m^2 + \sigma_n^2 + C_2} \right) \cdot \left(\frac{\sigma_{m,n} + C_3}{\sigma_m\sigma_n + C_3} \right), \end{aligned} \quad (8)$$

onde μ_m , μ_n e σ_m , σ_n representam, respectivamente, as médias e os desvios padrão das regiões locais m e n , e $\sigma_{m,n}$ indica a correlação entre as regiões. As constantes $C_1 = 6,5025$, $C_2 = 58,5225$ e $C_3 = \frac{C_2}{2}$ têm como função estabilizar cada componente [10]. Os índices SSIM locais calculados para janelas de $11 \times 11 \times 11$ voxels com sobreposição para cada posição espacial $s = (x, y, z)$ da imagem são sumarizados em um índice SSIM global por meio da média dos índices locais.

2.6 Formulação do Modelo Proposto

A relação entre o índice SSIM e o número de iterações do RADF foi investigada com o objetivo de determinar o número ótimo de iterações⁴ para a remoção do ruído de imagens de RM do cérebro humano, sem contudo, borrar ou destruir as bordas entre os tecidos cerebrais nas imagens.

Nos experimentos, os índices SSIM foram calculados usando uma imagem de RM do cérebro sem ruído (imagem de controle), e a mesma imagem com ruído ($\kappa\%$ de ruído Riciano) pré-processada pelo RADF com diferentes números de iterações. A Figura 1 mostra os resultados desses experimentos para $\kappa = 2, 3, 4, 5, 6$ e 7% de ruído.

Observando as curvas da Figura 1 nota-se que, independentemente do nível de ruído nas imagens, o índice SSIM aumenta de maneira consistente com o número de iterações do RADF até atingir um valor máximo e depois diminui novamente a medida que a imagem é continuamente borrada. Esses resultados sugerem que essas relações apresentam um comportamento característico e aparentemente similar, onde a alteração do nível de ruído da imagem gera apenas uma mudança na escala e um deslocamento dos gráficos, ou seja, as curvas parecem ter a mesma forma funcional.

Para confirmar a veracidade dessa observação, determinou-se por meio de ajustes (“fitting”) que, de fato, as curvas podem ser representadas por uma família de funções, que nesse caso corresponde a uma distribuição do tipo Weibull, indicada como:

$$W(t, k, \lambda) = \begin{cases} \left(\frac{k}{\lambda}\right) \left(\frac{t}{\lambda}\right)^{k-1} e^{-\left(\frac{t}{\lambda}\right)^k} & , t > 0 \\ 0 & , \text{ caso contrário} \end{cases} \quad (9)$$

onde k e λ são chamados, respectivamente, de parâmetros de forma e de escala.

Com base nos gráficos da Figura 1 e nos resultados dos ajustes das curvas na Tabela 1, observa-se que o parâmetro de forma k apresenta uma variação muito pequena com o nível de ruído da imagem. Fixando esse parâmetro como $k = 1,76$ observa-se que os valores dos parâmetros de escala λ para as diferentes curvas possuem uma relação linear com o valor do ruído σ_b . Essa observação foi comprovada via regressão linear, como mostra o gráfico da Figura 2, onde obteve-se $\lambda(\sigma_b) = 3,30 + 0,091\sigma_b$ com erro padrão $\varepsilon = 0,3921\%$.

Usando as relações descritas anteriormente, o número ótimo de iterações (t^*) do RADF pode então ser determinado como função do nível de ruído σ_b a partir do cálculo do valor máximo da função de distribuição Weibull dada em (9). Assim, derivando-se W em função de t e igualando o resultado a zero, tem-se:

⁴A palavra ótimo nesse contexto refere-se ao número de iterações que maximiza o valor do índice SSIM. Embora esse índice tenha sido desenvolvido com base na teoria da percepção visual humana, ele se correlaciona muito bem com a qualidade obtida na segmentação automática das imagens.




Figura 1. Gráfico das relações entre o índice SSIM e o número de iterações do RADF calculados para imagens com inserção de diferentes níveis de ruído κ .

$\kappa\%$	Ruído estimado(σ_b)	k	λ	$\epsilon(\%)$
2	55,6	1,7637	8,07	0,1153
3	77,8	1,7625	10,47	0,1454
4	99,3	1,7651	12,87	0,0737
5	120,8	1,7688	14,07	0,0985
6	140,8	1,7646	16,47	0,1064
7	160,8	1,7639	17,67	0,0584

Tabela 1. Valores estimados do ruído (σ_b), dos parâmetros da função de distribuição Weibull (parâmetros de forma (k) e de escala (λ)) e dos respectivos erros padrões de ajustes (ϵ) variando-se o nível de ruído κ inserido nas imagens.

$$\frac{dW(t)}{dt} = \frac{\left((k^2 - k) t^k \lambda^k - k^2 t^{2k}\right) e^{-\left(\frac{t}{\lambda}\right)^k}}{t^2 \lambda^{2k}} = 0 . \tag{10}$$




Figura 2. Ajuste linear entre os valores do parâmetro de escala λ da função de distribuição Weibull e o nível de ruído σ_b das imagens de RM de cérebro. O erro padrão do ajuste nesse caso foi de 0,3921%.

Resolvendo (10), para $t > 0$ e constantes $k = 1,76$ e $\lambda = \lambda_{\sigma_b} = \lambda(\sigma_b)$, obtém-se finalmente:

$$t^*(\sigma_b) = \left(\lambda_{\sigma_b}^k - \frac{\lambda_{\sigma_b}^k}{k} \right)^{\frac{1}{k}}, \quad (11)$$

que é o número ótimo de iterações do RADF que maximiza o valor do índice estrutural de qualidade da imagem. Portanto, uma vez estimado o valor do ruído de fundo (σ_b) da imagem, obtém-se facilmente o número ótimo de iterações (t^*) do RADF.

3 Resultados e Discussões

A Figura 3 mostra um corte axial de uma imagem de RM do cérebro corrompida com $\kappa = 5\%$ de ruído e sem a presença de heterogeneidades na intensidade dos níveis de cinza




Figura 3. Imagens de RM do cérebro com ruído $\kappa = 5\%$ após 1, 3, 6, 9*, 12 e 15 iterações do RADF. O sinal * indica o número ótimo de iterações determinado automaticamente pelo método proposto.

("biasfield"). A imagem foi processada com o RADF variando-se o número de iterações do algoritmo. Os números de iterações e os respectivos índices SSIM, calculados para as imagens resultantes do pré-processamento com o RADF, são indicados.

Observando-se o aspecto visual das imagens é possível notar que a imagem 3(d), obtida com o número ótimo de iterações determinado automaticamente, corresponde a uma imagem com pouco ruído e com um bom contraste entre os tecidos cerebrais. Para as imagens 3(a)-(c), uma quantidade significativa de ruído pode ser ainda observada nos tecidos




Figura 4. Resultados do pré-processamento de uma imagem com $\kappa = 2\%$ de ruído usando o RADF.

cerebrais branco e cinzento. Por outro lado, embora nas imagens 3(e) e (f) o ruído tenha sido praticamente eliminado, essas imagens apresentam um baixo contraste entre as bordas dos tecidos, causado pelo borramento excessivo das imagens.

A Figura 4 ilustra uma imagem corrompida com $\kappa = 2\%$ de ruído. Neste caso, o número ótimo de iterações determinado automaticamente pelo modelo proposto foi igual a 5, com índice SSIM=0,6880 associado. As diferenças absolutas entre as imagens antes e depois do pré-processamento também são apresentadas para o número de iterações ótimo ($t^*=5$) e para 10 iterações. Comparando-se as imagens 4(d) e 4(g) é possível observar que na última, além do ruído, uma grande quantidade de informação estruturada é removida. Isso pode também ser verificado analisando-se os seus respectivos histogramas em 4(e) e 4(h).

De maneira similar a descrita acima, a Figura 5 ilustra uma outra imagem corrompida com $\kappa = 4\%$ de ruído. Nesse caso, o número ótimo de iterações automaticamente determinado foi igual a 8, com índice SSIM=0,6539 associado. Comparando com os valores obtidos com o experimento da Figura 4, observa-se que um número maior de iterações foi necessário para se obter o valor máximo do índice SSIM, que nesse caso é menor que o obtido para a imagem com $\kappa = 2\%$ de ruído. Obviamente, esse fato se justifica pela maior degradação da imagem original e a dificuldade cada vez maior de se obter uma imagem pré-processada mais próxima da imagem de controle.

A fim de demonstrar a generalização do método proposto para imagens clínicas reais, uma imagem de RM de cérebro de um paciente com Esclerose Múltipla, indicada na Figura 6, foi utilizada. A imagem pertence a um banco de imagens da Faculdade de Medicina do Hospital das Clínicas de Ribeirão Preto. Neste caso, o número ótimo de iterações determinado pelo método proposto foi igual a 4, que indica um baixo nível de ruído. O valor do índice SSIM não foi calculado neste caso devido a inexistência de uma imagem de controle. As diferenças absolutas entre as imagens antes e depois do pré-processamento são apresentadas para melhor visualização do efeito do RADF. Comparando as imagens 6(b) e (e) e os histogramas 6(c) e (f) observa-se que a quantidade de informação estruturada removida no pré-processamento com 8 iterações do RADF é muito maior que para o valor ótimo de iterações.

A Figura 7 ilustra o efeito do número de iterações do algoritmo RADF nos resultados da segmentação das imagens de RM do cérebro. Nesse exemplo, as imagens 7(a)-(c) correspondem, respectivamente, à imagem original corrompida com $\kappa = 3\%$ de ruído e aos resultados do pré-processamento da imagem 7(a) pelo RADF com o número ótimo de iterações, determinado como igual a 6, e com 15 iterações. A segmentação foi realizada por meio de um modelo finito de mistura de Gaussianas [18] usando apenas imagens de RM ponderadas em T1. Observando a imagem segmentada 7(d) nota-se visivelmente que a presença de ruído na imagem 7(a) gera espúrios no resultado da segmentação em 7(d). No caso da imagem 7(f), nota-se que uma grande quantidade de detalhes é perdida na segmentação devido ao baixo




Figura 5. Resultados do pré-processamento de uma imagem com $\kappa = 4\%$ de ruído usando o RADF.






Figura 6. Resultados do processamento de uma imagem clínica.


contraste entre as bordas dos tecidos da imagem pré-processada 7(c). Finalmente, observa-se que a imagem segmentada em 7(e) não possui espúrios devido a presença de ruído e os detalhes entre as fronteiras dos tecidos foram preservados. A Tabela 2 apresenta uma análise quantitativa dos resultados da segmentação apresentados na Figura 7. Como pode-se comprovar, os melhores resultados da segmentação, em relação as taxas de Verdadeiro-Positivos (TPR), Falso-Positivos (FPR) e Acurácia (ACC) correspondem, de fato, a imagem processada com o número ótimo de iterações determinado pelo método proposto.



(a) $\kappa = 3\%$ ruído, SSIM=0,2031



(b) $t^* = 6$, SSIM=0,6654



(c) $t = 15$, SSIM = 0,3843



(d) segmentação de (a)



(e) segmentação de (b)



(f) segmentação de (c)

Figura 7. Resultados da segmentação para uma imagem com $\kappa = 3\%$ de ruído e processada com o número ótimo de iterações e com 15 iterações do RADF.

Iterações t	Massa branca			Massa cinzenta			Líquido cefalorraquidiano		
— — —	TPR	FPR	ACC	TPR	FPR	ACC	TPR	FPR	ACC
0	0,97	0,01	0,93	0,72	0,09	0,93	0,98	0,00	0,98
6*	1,0	0,00	0,99	1,0	0,00	0,99	1,0	0,00	1,0
15	0,83	0,04	0,97	1,0	0,00	0,97	0,98	0,00	1,0

Tabela 2. Análise quantitativa dos resultados da segmentação ilustrados na Figura 7(d)-(f).
O sinal * indica o número ótimo de iterações.

4 Conclusões e Considerações Finais

Um novo método para a determinação automática do número ótimo de iterações do RADF foi proposto neste trabalho. O método usa um modelo estatístico que relaciona o número de iterações do RADF com o valor do índice de qualidade estrutural (SSIM) de uma imagem. Dessa forma, por meio da maximização do índice SSIM, obtêm-se o número ótimo de iterações. Embora o número ótimo de iterações seja determinado a partir de um índice de qualidade visual, alguns experimentos mostraram uma boa correlação entre o índice e a qualidade da segmentação das imagens. Uma outra vantagem do método proposto, é que este permite o cálculo direto (sem a necessidade de análise a cada iteração) do número ótimo de iterações, visto que o modelo estatístico relacionando o índice SSIM e o nível de ruído da imagem determinado de maneira “off-line”, ou seja, antes do processamento da imagem.

Embora o modelo proposto tenha sido determinado a partir de imagens de RM simuladas, alguns testes foram realizados com imagens clínicas para comprovar a sua generalização e eficácia. Nesse trabalho, apenas imagens ponderadas em T1 foram utilizadas. No entanto, o mesmo procedimento pode ser utilizado para imagens ponderadas em T2 e PD. Finalmente, cabe observar que embora o mesmo procedimento proposto neste trabalho para a obtenção do modelo estatístico possa ser aplicado a outras modalidades de imagens e estruturas anatômicas, uma imagem de referência será sempre necessária. Por causa dessa limitação, um novo modelo está sendo investigado no qual o índice de qualidade de referência completa é substituído por um índice de qualidade às cegas (“blinded”), ou seja, um índice sem referência fixa.

Agradecimentos

Os autores são gratos à Fundação de Amparo à Pesquisa do Estado de São Paulo (Fapesp) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo

apoio financeiro a esse projeto de pesquisa (processo: 2008/09050-2) e também à aluna de doutorado da FMRP, Paula Rejane B. Diniz, pela seleção de imagens clínicas utilizadas nos experimentos.

Referências

*

- [1] J. Zhong and R. Ning, “Image Denoising Based on Wavelets and Multifractals for Singularity Detection,” *IEEE Transactions on Image Processing*, vol. 14, no. 10, pp. 1435–1447, 2005.
- [2] G. Fan and X. Xia, “Image Denoising Using a Local Contextual Hidden Markov Model in the Wavelet Domain,” *IEEE Signal Processing Letters*, vol. 8, no. 5, pp. 125–128, 2001.
- [3] G. Gerig, O. Kubler, R. Kikinis, and F. Jolesz, “Nonlinear Anisotropic Filtering of MRI Data,” *IEEE Transactions on Medical Imaging*, vol. 11, no. 2, pp. 221–232, 1992.
- [4] P. Perona and J. Malik, “Scale-Space and Edge Detection Using Anisotropic Diffusion,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 7, pp. 629–639, 1990.
- [5] M. Lysaker, A. Lundervold, and X. Tai, “Noise Removal Using Fourth-Order Partial Differential Equation With Applications to Medical Magnetic Resonance Images in Space and Time,” *IEEE Transactions on Image Processing*, vol. 12, no. 12, pp. 1579–1590, 2003.
- [6] J. Suri, D. Wilson, and S. Laximinarayan, eds., *Wavelets in Medical Image Processing: Denoising, Segmentation, and Registration*. Handbook of Medical Image Analysis: Advanced Segmentation and Registration Models, New York, NY: Kluwer Academic Publishers, 2004.
- [7] R. Ferrari and R. Winsor, “Digital Radiographic Image Denoising via Wavelet-based Hidden Markov Model Estimation,” *Journal of Digital Imaging*, vol. 18, no. 2, pp. 154–167, 2005.
- [8] E. Candès and F. Guo, “New Multiscale Transforms, Minimum Total Variation Synthesis: Applications to Edge-Preserving Image Reconstruction,” *Signal Processing*, vol. 82, no. 11, pp. 1519–1543, 2002.

- [9] C. Barcelos, M. Boaventura, and E. Silva-Jr, "Edge detection and noise removal by use of a partial differential equation with automatic selection of parameters," *Computational & Applied Mathematics*, vol. 24, no. 1, pp. 131–150, 2005.
- [10] Z. Wang, A. Bovik, H. Sheikh, and E. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, 2004.
- [11] B. Aubert-Broche, M. Griffin, G. Pike, A. Evans, and D. Collins, "Twenty New Digital Brain Phantoms for Creation of Validation Image Data Bases," *IEEE Transactions on Medical Imaging*, vol. 25, no. 11, pp. 1410–1416, 2006.
- [12] M. Black, G. Sapiro, D. Marimont, and D. Heeger, "Robust Anisotropic Diffusion," *IEEE Transactions on Image Processing*, vol. 7, no. 3, pp. 421–432, 1998.
- [13] M. Black and G. Sapiro, "Edges as Outliers: Anisotropic Smoothing using Local Image Statistics," *Scale-Space Theories in Computer Vision - Lectures Notes in Computer Science*, vol. 1682, pp. 259–270, 1999.
- [14] R. Nowak, "Wavelet-based Rician noise removal for magnetic resonance imaging," *IEEE Transactions on Image Processing*, vol. 8, no. 10, pp. 1408–1419, 1999.
- [15] R. Henkelman, "Measurement of Signal Intensities in the Presence of Noise in MR Images," *Medical Physics*, vol. 12, no. 2, pp. 232–233, 1985.
- [16] L. Kaufman and L. Crooks, "Measuring Signal-to-Noise Ratios in MR Imaging," *Radiology*, vol. 173, pp. 265–267, 1989.
- [17] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [18] S. Aylward and S. Pizer, "Continuous gaussian mixture modeling," in *Proceedings of the Information Processing in Medical Imaging* (James Duncan, ed.), pp. 176–189, 1997.