

XXVII Brazilian Congress in Biomedical Engineering
October 26-30 2020 Vitoria (Brazil)



CBEB2020

XXVII Congresso Brasileiro
de Engenharia Biomédica

Filtragem de Ruído Riciano em Imagens de Ressonância Magnética Utilizando Transformada de Estabilização de Variância

Vinícius P. Campos¹ e Marcelo A. C. Vieira¹

¹ Dep. de Eng. Elétrica e de Computação, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil

Abstract— Magnetic resonance imaging (MRI) is of great interest in medicine because it provides high quality images without exposing the patient to ionizing radiation. However, MRI images are susceptible to intrinsic degradation of the acquisition process, such as the addition of noise, which can impair medical diagnosis. Image processing techniques can filter the noise and improve image quality, making them useful tools in the medical field. Denoising performance depends on the accurate modeling of the noise characteristics in the images. Many works in the literature report different techniques for denoising MRI images, however, very few use the correct and accurate model for the different acquisition modalities, such as the number of coils, the reconstruction algorithm and the use or not of parallel (accelerated) acquisition. Thus, this work presents different methods to remove noise from MRI images, in which the correct noise model is adopted according to the acquisition mode. In addition, this work shows how a variance stabilization transformation can be used before the image processing, improving the performance of the denoising algorithm. The validation procedures were conducted using synthetic MRI images of a human brain (BrainWeb phantom) corrupted by different noise patterns, generally observed in clinical MRI exams. Noisy images were processed by different denoising algorithms and the results showed improved performance when the adequate model for each acquisition modality was considered.

Keywords— Magnetic Resonance Imaging, Image Processing, Image Denoising, Rician Noise

I. INTRODUÇÃO

Ruído é um problema presente na maioria das modalidades de imagens utilizadas na medicina. Imagens corrompidas por ruído podem dificultar o diagnóstico médico e, por esse motivo, técnicas de processamento de imagens, visando a remoção dessas distorções, são de suma importância. No caso das imagens de ressonância magnética, o ruído é provocado principalmente pela interação do objeto com o campo magnético e pelo efeito térmico devido à eletrônica presente no sistema de aquisição [1].

Estatisticamente falando, o ruído em MRI pode ser modelado por uma distribuição de probabilidade Rician ou Non Central Chi. Essas diferentes distribuições estão diretamente relacionadas com o processo de aquisição do sinal, mais especificamente, com o número de bobinas e também com o algoritmo utilizado para a reconstrução da imagem final [1, 2].

Apesar de essas características estatísticas serem bastante exploradas na literatura [1, 3, 2, 4], é comum ainda a existência de trabalhos reportando a adoção de um modelo de ruído gaussiano, branco e aditivo (AWGN - *Additive White Gaussian Noise*) para filtragem do ruído presente em imagens de MRI. Isso se deve ao fato de que, em regiões com alta relação sinal-ruído (SNR - *Signal to Noise Ratio*), as distribuições Rician e Non Central Chi tendem a se comportar como uma distribuição Gaussiana [5]. Todavia, existe um grande viés nessa premissa. A tendência Gaussiana, por si só, não contempla todas características de um ruído AWGN; mais especificamente, que o ruído é homoscedástico, ou seja, que é independente e igualmente distribuído (i.i.d) em toda a imagem [6]. Dessa forma, mesmo quando o ruído pode ser aproximado por uma distribuição Gaussiana, sua variância, e consequentemente o desvio padrão, podem não ser igualmente distribuídos ao longo da imagem, pois podem ser dependentes da intensidade e/ou da posição espacial do pixel, ou seja, o ruído é heteroscedástico. Esse é o caso encontrado na grande maioria das imagens produzidas por equipamentos de MRI. Sendo assim, assumir um modelo AWGN para filtragem de imagens de MRI, pode prejudicar significativamente o desempenho dos algoritmos de filtragem de ruído e comprometer a qualidade da imagem final processada.

Para o caso de imagens corrompidas por outros tipos de ruído, como no caso de MRI, a abordagem mais utilizada é a de desenvolver métodos de filtragem específicos para cada tipo de ruído [7, 8]. No entanto, uma alternativa a essa abordagem é a de transformar o ruído heteroscedástico em homoscedástico, antes da filtragem do ruído, utilizando, para isso, uma transformada de estabilização de variância (VST - *Variance Stabilization Transformation*) [3]. Assim, a proposta deste trabalho é utilizar o conceito de

VST para transformar matematicamente o ruído Riciano, heteroscedástico, presente nas imagens de MRI, em ruído homocedástico aproximadamente Gaussiano, antes da etapa de filtragem. A grande vantagem dessa abordagem é o fato de que o ruído de variância constante, homoscedástico, é mais fácil de ser removido da imagem e, além disso, existem diversos trabalhos e algoritmos de filtragem com resultados excelentes focados nesse tipo de ruído [9], muito mais comum do que métodos de filtragem desenvolvidos especificamente para ruído Riciano ou Non Central Chi.

Será apresentada nesse trabalho uma análise comparativa e objetiva entre os resultados da filtragem de imagens de MRI quando o modelo AWGN é adotado, com os resultados obtidos pela abordagem proposta nesse trabalho, na qual um modelo mais adequado é utilizado para transformar o ruído da imagem antes da filtragem, por meio de uma VST desenvolvida especificamente para estabilização da variância de ruído Riciano [3].

II. TEORIA

Antes de abordar as especificidades do ruído presente em imagens de MRI, algumas propriedades gerais dos diferentes comportamentos de um ruído serão apresentadas a seguir:

A. Ruído homoscedástico

Um ruído é dito do tipo homoscedástico quando a variância de sua distribuição, em diferentes realizações, é constante, ou seja, independe da intensidade do sinal original bem como da posição espacial do mesmo. Trazendo essa definição para caso de imagens digitais, isso significa que, independentemente da intensidade e da localização espacial do pixel, a variância da distribuição será constante. O termo homoscedástico está diretamente relacionado, então, com o termo independente e igualmente distribuído (i.i.d.) [6].

A distribuição característica de ruídos desse tipo é a Gaussiana (ou Normal). Mais especificamente, temos a denominação AWGN, em referência a um ruído aditivo branco gaussiano. O termo **branco** se dá pelo fato de que afeta todas as frequências do sinal original de igual maneira. Já o termo **aditivo** se dá pelo fato de o ruído ser adicionado ao valor do sinal original, conforme equação 1, em que $M(x)$ é a imagem ruidosa nas coordenadas espaciais x , $A(x)$ é a imagem original sem ruído e $N(x)$ é o ruído aleatório que segue uma distribuição Gaussiana com média 0 e variância constante σ_n^2 , $N(0, \sigma_n^2)$. Esses dois termos juntos definem o conceito de homoscedasticidade [6].

$$M(x) = A(x) + N(x) \quad (1)$$

Importante ressaltar que esse tipo de ruído já foi bastante estudado na literatura e grande parte dos algoritmos de filtragem se baseiam nessa distribuição característica. Sendo assim, trabalhar com esse tipo de distribuição tende a garantir uma melhor performance no resultado final [6, 10].

B. Ruído heteroscedástico

O termo heteroscedástico é atribuído quando a variância do ruído não é a mesma em toda a imagem. Isso pode ocorrer quando a variância do ruído depende da intensidade do pixel ou quando depende da sua posição espacial; ou, também, quando a variância é dependente dos dois fatores ao mesmo tempo: intensidade e posição. Dessa forma, esse ruído não pode mais ser modelado como AWGN [6]. Ruídos desse tipo estão relacionados a diversas distribuições, dentre elas a Riciano, característica de imagens de MRI. Esse tipo de ruído é mais complexo que o AWGN e deve ser modelado corretamente de forma a não haver erros nos algoritmos de filtragem de ruído.

C. Ruído Riciano estacionário

Primeiramente, antes de descrever os detalhes matemáticos e estatísticos do ruído presente nas imagens de MRI, vale ressaltar que a teoria apresentada neste trabalho segue o contexto geral de aquisição em MRI. Sendo assim, assume-se que: os dados são adquiridos no espaço-k utilizando a trajetória Cartesiana regular; diferentes contribuições do ruído são tratadas de forma independente, de modo que o ruído total no sistema é advindo da contribuição individual de cada fonte; pós-processamento e técnicas de correção não são aplicadas [5]. Dessa forma, alguns casos não são considerados, tais como: interpolação devido à amostragem Não-Cartesiana; pós-processamento para correção de artefatos para protocolos de aquisição específicos como EPI (*Echo-planar Imaging*), dentre outros. Muitos desses cenários são específicos de alguns fabricantes e modelos de equipamentos de MRI ou dependem de uma sequência de pulsos específica. As características do ruído mudariam drasticamente e estudos aprofundados se tornam necessários para esses casos [5].

Seguindo, então, o contexto geral, sabe-se que uma das principais fonte de ruído em aquisições de MRI é o ruído eletrônico (ou térmico), proveniente, como o próprio nome já sugere, dos componentes eletrônicos existentes nos equipamentos [1]. O sinal em MRI é adquirido diretamente no domínio de Fourier, também chamado de espaço-k. Matematicamente, no espaço-k (e somente no espaço-k), esse tipo de ruído é modelado como um ruído AWGN [5].

Posteriormente, dois passos são executados: (1) transformada inversa discreta de Fourier e (2) módulo da imagem resultante no passo 1. Com isso, chega-se ao que se conhece como *imagem de magnitude*, que são as imagens efetivamente visualizadas pelos médicos durante o exame. Com isso, o sinal no espaço-k, corrompido por ruído Gaussiano homoscedástico, passa a ser corrompido por ruído Riciano heteroscedástico no domínio da imagem [5, 3].

Seja $M(k)$ os dados amostrados no espaço-k, tem-se:

$$M(k) = A(k) + N(k), \quad (2)$$

em que $A(k) = A_r(k) + jA_i(k)$ é o sinal complexo sem ruído decomposto em parte real e imaginária, representados, respectivamente, pelos índices r e i . De forma análoga, $N(k) = N_r(k) + jN_i(k)$ representa o ruído complexo AWGN, em que $N_r(k)$ e $N_i(k)$ seguem uma distribuição Gaussiana com média zero e variância σ_n^2 , $N(0, \sigma_n^2)$.

Seja $M(x)$, a imagem de magnitude ruidosa de MRI, obtida após aplicação dos passos (1) e (2) citados anteriormente, tem-se:

$$M(x) = |iDFT(M(k))|, \quad (3)$$

em que $iDFT(\cdot)$ representa a transformada inversa discreta de Fourier e $|\cdot|$ o módulo aplicado ao sinal após a $iDFT(\cdot)$. A partir das equações 2 e 3 e sabendo que há uma relação direta entre a posição k (no espaço-k) e x (na imagem de magnitude), tem-se [5]:

$$M(x) = \sqrt{(A_r(x) + N_r(x))^2 + (A_i(x) + N_i(x))^2} \quad (4)$$

A variância de $M(x)$, condicionada ao sinal sem ruído $A(x)$, é descrita por [3] :

$$var(M(x)|A(x), \sigma_n) = 2\sigma_n^2 + A(x)^2 - \frac{\pi\sigma_n^2}{2} L\left(-\frac{A(x)^2}{2\sigma_n^2}\right)^2 \quad (5)$$

em que $L(y) = e^{\frac{y}{2}} [(1-y)I_0(-\frac{y}{2}) - yI_1(-\frac{y}{2})]$, $y = -\frac{A(x)^2}{2\sigma_n^2}$ e I_n denota a função Bessel modificada de ordem n . Para altos valores de SNR, isto é, altos valores de $A(x)$ em relação a σ_n , a equação pode ser aproximada por [3] :

$$var(M(x)|A(x), \sigma_n) \approx \sigma_n^2 - \frac{\sigma_n^4}{2A(x)^2} \quad (6)$$

Percebe-se, pelas equações 5 e 6, que a variância do sinal $var(M(x)|A(x))$ não é constante em toda a imagem. Mais ainda, nota-se que ela depende diretamente da intensidade do sinal sem ruído $A(x)$ e da sua relação com σ_n , ou seja,

o ruído Riciano é dependente do sinal, ou seja, é do tipo heteroscedástico. Como a variância depende **somente** do sinal, pode-se dizer, então, que o ruído é do tipo Riciano estacionário. Em MRI, esse é o típico caso de exames em que se utiliza uma única bobina na aquisição do sinal [5].

D. Ruído Riciano não-estacionário

Além da dependência do sinal, vista anteriormente, a variância do ruído Riciano pode ser também dependente do espaço. Consequentemente, o ruído é dito do tipo não-estacionário. Em MRI, esse cenário ocorre sempre que tivermos aquisição com múltiplas bobinas (devido à correlação espacial entre elas, gerando correlação do ruído entre os dados em diferentes posições) e quando é utilizado uma sequência acelerada ou paralela (devido à utilização de algoritmos de interpolação para os dados não amostrados, gerando também correlação do ruído entre os dados em diferentes posições) [5]. Dentre os diferentes algoritmos de aceleração, o *Sensitivity Encoding* (SENSE) e o *Generalized Autocalibration Parallel Acquisition* (GRAPPA) são os mais utilizados. Porém, o GRAPPA gera uma imagem com distribuição Non Central Chi e não será abordado nesse trabalho [5].

Para o caso não-estacionário, o termo σ_n da equação 6 depende da posição espacial do pixel [1, 5]. Logo, tem-se $\sigma_n(x)$. Dessa forma, podemos reescrever a equação 6 como

$$var(M(x)|A(x), \sigma_n(x)) \approx \sigma_n(x)^2 - \frac{\sigma_n(x)^4}{2A(x)^2}. \quad (7)$$

Nota-se, então, que a variância agora depende não só do sinal sem ruído $A(x)$ como também do parâmetro $\sigma_n(x)$ que varia de acordo com a posição espacial.

De forma resumida, podemos elencar os cenários de ruído em MRI conforme Tabela 1.

Tabela 1: Resumo das distribuições de ruído em MRI.

Bobinas	Acelerada	Distribuição	Estacionário
Uma	—	Riciana	Sim
Múltiplas	SENSE	Riciana	Não

E. Transformada de estabilização de variância

Conforme relatado, ao analisar a equação 6, nota-se que a variância do ruído depende do sinal original sem ruído $A(x)$. Para tratar dessa dependência do sinal, em [3], o autor propõe, por meio de métodos de otimização numérica, uma VST capaz de transformar o ruído Riciano heteroscedástico,

presente em imagens de MRI, em ruído homoscedástico aproximadamente Gaussiano, com média zero e variância constante.

Dessa forma, após o uso da VST, a imagem ruidosa, agora denominada $M_{vst}(x)$, pode ser descrita como

$$M_{vst}(x) \approx A_{vst}(x) + N(x) \quad (8)$$

em que $A_{vst}(x)$ representa o sinal livre de ruído no domínio da transformada e $N(x)$ o ruído transformado aproximadamente homoscedástico, Gaussiano, com média 0 e variância constante σ^2 , $N(0, \sigma^2)$. Mais ainda, a proposta em [3] otimiza o processo para que o ruído da imagem passe a ter uma variância próxima de 1. Dessa forma, a variância de $M_{vst}(x)$, condicionada à média $A_{vst}(x)$ pode ser descrita como

$$\text{var}(M_{vst}(x)|A_{vst}(x)) \approx \sigma^2 \approx 1. \quad (9)$$

Assim, no domínio da transformada, pode-se utilizar qualquer algoritmo de filtragem desenvolvido para o modelo AWGN para a remoção do ruído dessa imagem, o que é uma grande vantagem, já que o ruído AWGN é mais fácil de ser removido.

Em termos de estimativa de parâmetros para que a transformada possa ser realizada, um único parâmetro, σ_n , da distribuição Riciana necessita ser estimado. Em [3], o autor também propõe um algoritmo para essa estimativa. Vale ressaltar que a estimativa e a própria VST foram elaboradas para ruído Riciano estacionário. Para o caso não-estacionário, no entanto, pode-se usar a estimativa da matriz $\sigma_n(x)$ abordada em [1].

Finalizando o conceito de VST, deve-se mencionar que, após a filtragem da imagem estabilizada, uma transformada inversa necessita ser aplicada, trazendo a imagem para sua faixa de valores originais. Em termos de notação, utilizaremos VST^{-1} .

Com isso, podemos estabelecer quatro passos para a correta filtragem de ruído Riciano em imagens de MRI:

1. Estimar σ_n (para o caso estacionário) ou $\sigma_n(x)$ (para o caso não-estacionário);
2. Aplicar a VST;
3. Filtrar a imagem estabilizada;
4. Aplicar a VST^{-1} ;

III. MATERIAIS E MÉTODOS

A partir do embasamento teórico apresentado em II, nesse item serão abordados os materiais e métodos utilizados nesse trabalho. Em termos de implementação de código, o *software*

utilizado foi o MATLAB (*The Mathworks Inc.*), versão R2016a.

A. Banco de imagens do phantom BrainWeb

Para permitir uma análise objetiva do desempenho dos métodos de filtragem de ruído apresentados, utilizou-se o banco de imagens do *phantom BrainWeb* [11]. O *phantom* simula a aquisição do tipo T1 (*T1-weighted*) e as imagens possuem dimensão 217 x 181 pixels e quantização em 8 bits. A vantagem do uso de imagens sintéticas é a possibilidade de se usar métricas objetivas, que necessitam de uma imagem de referência sem ruído (*Ground Truth*), para avaliação da qualidade das imagens filtradas. Além disso, pode-se controlar a intensidade e a distribuição espacial do ruído Riciano a ser adicionado nas imagens (estacionário ou não-estacionário) para uma avaliação mais completa dos métodos apresentados.

A partir da imagem sem ruído, 100 realizações ruidosas foram obtidas utilizando-se dois diferentes padrões de distribuição de ruído típicos de exames clínicos de MRI, sendo um do tipo *Riciano estacionário*, com parâmetro $\sigma_n = 20$ (8% do valor máximo de intensidade) e outro do tipo *Riciano não-estacionário* com σ_n variando de 6 a 20 em valores absolutos (2% a 8% do valor máximo de intensidade). Esse padrão de ruído variante no espaço é típico de aquisição com múltiplas bobinas e acelerada SENSE [1, 5] e é ilustrado na Figura 2 (parte superior).

B. Algoritmo para estimativa e filtragem do ruído

Para a filtragem das imagens de MRI, foi utilizado o algoritmo proposto nesse trabalho (com VST) e também uma abordagem em que foi assumido que o ruído é aproximadamente AWGN. Para ambos os casos, o método de filtragem de ruído utilizado foi o *Block Matching and 3D filtering* (BM3D), desenvolvido especificamente para filtragem de ruído AWGN [9]. Vale ressaltar, porém, que outros algoritmos podem ser utilizados para a filtragem. Em termos de notação para esse trabalho, utilizaremos VST_BM3D e AWGN_BM3D respectivamente.

C. Métricas objetivas

Para as imagens sintéticas do *phantom BrainWeb*, além da inspeção visual das imagens, duas métricas objetivas foram aplicadas para avaliação da qualidade das imagens processadas. Elas são descritas a seguir:

- **Raiz do erro médio quadrático normalizado pela média (EQMn)**[10]

O cálculo do EQMn é dado por

$$EQMn(\hat{A}, A) = \sqrt{\frac{1}{XY} \sum_{x=1}^X \sum_{y=1}^Y \left(\frac{\hat{A}(x) - A(x)}{A(x)} \right)^2}, \quad (10)$$

em que A é a imagem original sem ruído, \hat{A} é a imagem filtrada, X e Y são as dimensões da imagem. A normalização é justificada como uma forma de medir o erro localmente e de forma ponderada. Em se tratando de filtragem de ruídos dependentes do sinal e/ou do espaço, deve-se entender que o objetivo é filtrar todos os níveis de cinza, de todos os pixels, de modo uniforme.

- **Índice de similaridade estrutural (SSIM)** [12]

Essa métrica, bastante utilizada para avaliação da qualidade de imagens, leva em conta parâmetros da imagem relativos ao sistema visual humano [12], como luminância, contraste e estrutura. Inicialmente, o SSIM é calculado de forma local, em regiões de tamanho 11×11 e, ao final, a média aritmética de todos índices locais é obtida, chegando-se ao SSIM global da imagem sendo avaliada.

Em relação aos valores numéricos do SSIM, quanto mais próximo de 1, mais a imagem sendo processada (\hat{A}) é similar à imagem de referência (A), com 1 sendo o valor máximo e representando o cenário ideal, quando as duas imagens são idênticas.

IV. RESULTADOS E DISCUSSÃO

A. Inspeção visual

As Figuras 1 e 2 mostram os resultados de filtragem da imagem do *phantom BrainWeb* corrompida pelos dois padrões de ruído, estacionário e não-estacionário, respectivamente. Em ambos cenários, o método VST_BM3D foi superior ao algoritmo AWGN_BM3D, o que pode ser verificado nas imagens ampliadas de uma região de interesse. A diferença é mais evidente ainda no caso do ruído não-estacionário. Nota-se bastante ruído residual na imagem filtrada pelo método AWGN_BM3D, principalmente no centro da região de interesse, diretamente relacionado com a distribuição espacial do ruído (ver Figura 2, parte superior). Esse fato é explicado pois, conforme abordado no item II, a variância do ruído depende da intensidade do sinal e da posição espacial do pixel. Sendo assim, ao usar um algoritmo que adota uma modelagem de ruído Gaussiano homoscedástico (AWGN), as características mencionadas não são levadas em consideração, afetando negativamente o

resultado do processo de filtragem.

B. Métricas objetivas

As Tabelas 2 e 3 mostram os resultados das métricas objetivas para os resultados referentes às imagens do *phantom BrainWeb* para ambos cenários: ruído estacionário e não-estacionário, respectivamente. Para o cálculo desses parâmetros foram processadas 100 imagens de cada distribuição de ruído e o valor médio, juntamente com o desvio padrão, são apresentados nas tabelas.




Figura 1: Resultado de filtragem para o caso de ruído Riciano estacionário. Na figura estão exibidas as imagens sem ruído, ruidosa (linha superior) e também os resultados de filtragem pelos métodos: AWGN_BM3D e VST_BM3D (linha inferior). À esquerda, as imagens completas e à direita uma região de interesse ampliada (referente à área delimitada em vermelho). É possível notar o melhor desempenho da proposta baseada em VST, em que a imagem resultante apresenta menos ruído residual.

Tabela 2: Métricas objetivas. Ruído Riciano estacionário. Na coluna de resultados, estão destacados, em negrito, os valores referentes ao algoritmo de melhor desempenho. A linha referente à imagem ruidosa foi mostrada para melhor compreensão do ganho obtido por meio dos métodos de filtragem.

Algoritmo	Métrica	Resultado
Ruidosa	EQMn	1.320 ± 0.060
AWGN_BM3D	EQMn	1.120 ± 0.040
VST_BM3D	EQMn	0.430 ± 0.070
Ruidosa	SSIM	0.540 ± 0.002
AWGN_BM3D	SSIM	0.840 ± 0.003
VST_BM3D	SSIM	0.858 ± 0.003

Confirmando a análise visual, os resultados mostram, de forma objetiva, o melhor desempenho do método baseado em VST. O método obteve melhor desempenho na filtragem do ruído para as duas métricas, EQMn e SSIM, para ambas as distribuições de ruído abordadas nesse trabalho.

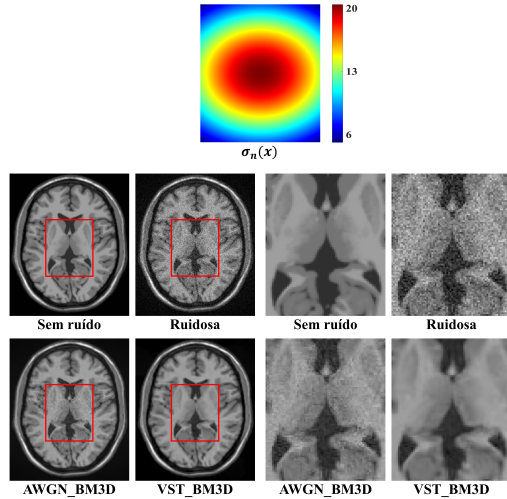


Figura 2: Resultado de filtragem para o caso de ruído Riciano não-estacionário. Na parte superior, o padrão de variação espacial do parâmetro $\sigma_n(x)$. A escala refere-se ao valor absoluto do parâmetro. Abaixo, estão exibidas as imagens sem ruído, ruidosa (linha mediana) e também os resultados de filtragem pelos métodos: AWGN_BM3D e VST_BM3D (linha inferior). À esquerda, as imagens completas e à direita uma região de interesse ampliada (referente à área delimitada em vermelho). É possível notar o melhor desempenho da proposta baseada em VST, em que a imagem resultante apresenta menos ruído residual.

Tabela 3: Métricas objetivas. Ruído Riciano não-estacionário. Na coluna de resultados, estão destacados, em negrito, os valores referentes ao algoritmo de melhor desempenho. A linha referente à imagem ruidosa foi mostrada para melhor compreensão do ganho obtido por meio dos métodos de filtragem.

Algoritmo	Métrica	Resultado
Ruidosa	EQMn	0.980 ± 0.005
AWGN_BM3D	EQMn	0.829 ± 0.004
VST_BM3D	EQMn	0.363 ± 0.006
Ruidosa	SSIM	0.622 ± 0.002
AWGN_BM3D	SSIM	0.824 ± 0.003
VST_BM3D	SSIM	0.874 ± 0.002

V. CONCLUSÃO

Os resultados obtidos indicam as vantagens do uso da metodologia baseada em VST para a filtragem de ruído de imagens de MRI. Em todos os cenários abordados, fica clara a importância do correto modelamento do ruído bem como da estabilização da variância antes da filtragem. Por último, reforça-se a grande aplicação da técnica em diversos subcampos de MRI. Diversos trabalhos fazem uso de pré-processamento das imagens para posterior aplicação em *softwares* de segmentação (*diffusion MRI*, por exemplo).

Sendo assim, com o melhor resultado da remoção de ruído espera-se que melhores resultados em etapas posteriores venham a ocorrer.

Além disso, outra consequência seria a redução do tempo e custo de exame. Em geral, os equipamentos fazem várias amostragens durante o processo de aquisição da imagem (um dos motivos para os longos tempos de exame). Essa abordagem visa a diminuição do ruído por meio de médias das amostragens realizadas. Ao utilizar o algoritmo de filtragem, no entanto, o número de amostras poderia ser reduzido, uma vez que o ruído seria removido por meio do processamento posterior da imagem.

CONFLITOS DE INTERESSE

Os autores declaram não haver conflitos de interesse.

REFERÊNCIAS

1. Aja-Fernández S, Pieciak T, Vegas-Sánchez-Ferrero G. Spatially variant noise estimation in MRI: a homomorphic approach. *Medical Image Analysis*. 2015;20(1):184–197.
2. Aja-Fernández S, Vegas-Sánchez-Ferrero G, Tristán-Vega A. About the background distribution in MR data: a local variance study. *Magnetic Resonance Imaging*. 2010;28(5):739–752.
3. Foi A. Noise estimation and removal in MR imaging: The variance-stabilization approach. In: *2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro*:1809–1814; IEEE; 2011.
4. Aja-Fernández S, Vegas-Sánchez-Ferrero G, Tristán-Vega A. Noise estimation in parallel MRI: GRAPPA and SENSE. *Magnetic Resonance Imaging*. 2014;32(3):281–290.
5. Vegas-Sánchez-Ferrero G, Aja-Fernández S. Statistical analysis of noise in MRI: modeling, filtering and estimation. Springer; 2016.
6. Azzari L, Borges LR, Foi A. Modeling and estimation of signal-dependent and correlated noise. In: *Denoising of Photographic Images and Video*:1–36; Springer; 2018.
7. Xie J, Heng PA, Shah M. Image diffusion using saliency bilateral filter. *IEEE Transactions on Information Technology in Biomedicine*. 2008;12(6):768–771.
8. Chandrashekar L, Sreedevi A. Assessment of non-linear filters for MRI images. In: *2017 Second International Conference on Electrical, Computer and Communication Technologies*:1–5; IEEE; 2017.
9. Dabov K, Foi A, Katkovnik V, Egiazarian K. Image denoising with block-matching and 3D filtering. In: *Image Processing: Algorithms and Systems, Neural Networks, and Machine Learning*:6064:606414; International Society for Optics and Photonics; 2006.
10. Borges LR, Azzari L, Bakic PR, Maidment AD, Vieira MAC, Foi A. Restoration of low-dose digital breast tomosynthesis. *Measurement Science and Technology*. 2018;29(6):064003.
11. Collins DL, Zijdenbos AP, Kollokian V, et al. Design and construction of a realistic digital brain phantom. *IEEE Transactions on Medical Imaging*. 1998;17(3):463–468.
12. Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*. 2004;13(4):600–612.