

NOVA METODOLOGIA DE FILTRAGEM DE RUÍDOS DE IMAGENS DE SENSORIAMENTO REMOTO POR RADAR

T. L. M. Barreto¹, R. A. S. Rosa¹, C. Wimmer¹, J. R. Moreira¹, L. S. Bins², J. Almeida³,
F. A. M. Cappabianco³, J. M. Lázaro¹

¹Bradar Indústria S.A., Brasil

²Instituto Nacional de Pesquisas Espaciais, Brasil

³Universidade Federal de São Paulo, Brasil

Comissão IV - Sensoriamento Remoto, Fotogrametria e Interpretação de Imagens

RESUMO

Este trabalho apresenta uma nova abordagem para a filtragem de fase nas imagens do Radar de Abertura Sintética Interferométrica (InSAR), denominada BMInSAR (Block-Matching InSAR). Ele usa o agrupamento k-means para resolver o problema de busca de similaridade de correspondência de bloco, simplificando assim as etapas de pré-processamento e filtragem de vários blocos de referência ao mesmo tempo. Além disso, propõe-se uma nova metodologia baseada em medições GPS de verdade para avaliar a qualidade de filtragem dos Modelos Digitais de Elevação (DEMs) derivados de um par de imagens complexas SAR de Alta Resolução (VHR). O conjunto de dados utilizado foi obtido pelo sensor aerotransportado OrbiSAR-2 da Bradar na banda X. O BMInSAR supera significativamente os métodos de filtragem de última geração, tanto na precisão quanto no tempo de execução. Depois de filtrar com o BMInSAR, obteve-se uma precisão de 21cm no DEM resultante de uma área de gramado homogêneo, bastante semelhante à obtida pela tecnologia LiDAR.

Palavras-chave: Processamento de Imagens SAR, Filtragem de Fase Interferométrica, BM3D.

ABSTRACT

This paper presents a novel approach for phase denoising in Interferometric Synthetic Aperture Radar (InSAR) images, named as Block-Matching InSAR (BMInSAR). It uses k-means clustering to solve the block matching similarity search problem, thus simplifying preprocessing steps and filtering several reference-blocks at once. Also, we propose a novel methodology based on ground-truth GPS measurements to assess the filtering quality of Digital Elevation Models (DEMs) derived from a pair of Very High-Resolution (VHR) SAR complex images. Our dataset was obtained by X-Band airborne sensor OrbiSAR-2 from BRADAR. BMInSAR significantly outperforms the state-of-the-art filtering methods in both accuracy and execution time. After filtering with BMInSAR, we achieved an accuracy of 21cm in the resulting DEM of a homogeneous lawn area, which is quite similar to that obtained by LiDAR technology.

Keywords: SAR Image Processing, Interferometric Phase Denoising, BM3D.

1- INTRODUÇÃO

Filtragem de ruídos de imagens de Radar de Abertura Sintética (SAR) é um assunto fundamental e crucial no sensoriamento remoto devido à presença do ruído *speckle*, que é inerente em sensores eletromagnéticos ativos que funcionam em comprimentos de onda de alta escala (por exemplo, 3cm em banda X e 70cm em banda P). Este fenômeno ocorre como resultado da interação das ondas eletromagnéticas com dispersores distribuídos aleatoriamente em uma determinada célula de resolução do meio ambiente. O sinal retornado contém

informações de fase e amplitude, que podem ser posteriormente reconstruídas por interferência construtiva ou destrutiva, resultando em pixels brilhantes ou escuros. Ao usar a técnica conhecida como Interferometria SAR (InSAR), o problema é ainda pior para os interferogramas, uma vez que são obtidos a partir da diferença de fase entre um par de imagens SAR. Portanto, um interferograma é o resultado de duas aquisições independentes contendo diferentes padrões de ruídos.

A qualidade dos interferogramas estimados tem importância direta em muitas aplicações. Modelos

de Elevação Digital (DEM), por exemplo, são interferogramas amplamente utilizados para engenharia civil, mapeamento de topografia, monitoramento de nível de água (Barreto et al., 2016a) e detecção de mudanças, como desmatamentos (Barreto et al., 2016b; Barreto et al., 2016c).

Os filtros anisotrópicos não-locais são o estado da arte em termos de precisão de remoção de ruído. Uma das abordagens amplamente utilizadas baseadas em tais filtros é o *Non-Local Means* (NLM) (Buades et al., 2005). Recentemente, o *Block-Matching 3D* (BM3D) (Dabov et al., 2006; Buades et al., 2004) tornou-se popular, fazendo uso de blocos semelhantes para filtrar intra e inter blocos simultaneamente. Desde então, variações e melhorias incluem a redução da dimensionalidade usando estruturas locais (LARK) e PCA (Bashar, 2015).

Neste trabalho, apresenta-se uma abordagem inovadora para filtragem interferométrica baseada em BM3D, denominada *Block-Matching InSAR* (BMInSAR). Sua principal vantagem é eliminar a necessidade de aplicar um conjunto de etapas geralmente necessárias, como limiar, estimativa de intensidade de ruído e redução de dimensionalidade. Além disso, propomos uma nova metodologia para avaliar a qualidade de filtragem de DEMs que depende de pontos de controle de campo de GPS. Os resultados obtidos mostraram que o método proposto supera as abordagens de última geração em termos de precisão e tempo de execução.

2- FILTRAGEM DE RUÍDO DE FASE INSAR POR SIMILARIDADE E CORRESPONDÊNCIA DE BLOCOS

Da mesma forma que a abordagem BM3D, a abordagem proposta adota uma janela de busca com tamanho ω^2 movendo-se com um passo β dentro do domínio da imagem A . Em seguida, esta janela de pesquisa é dividida em blocos sobrepostos de tamanho menor p com tamanho s^2 , que são então empilhados por similaridade. A informação dos blocos empilhados é então usada para filtrar seus pixels usando a informação intra-bloco.

Para encontrar mapeamentos semelhantes, aplica-se um agrupamento *k-means* para encontrar k grupos, de modo que cada grupo seja então filtrado usando as informações inter-bloco. Um conjunto de blocos p pode ser traduzido para um espaço de características de n observações por m dimensões usando as Equações 1 e 2.

$$n = (w - 0.5s)^2 \quad (1)$$

$$m = s^2 \quad (2)$$

Em seguida, obtém-se uma lista de etiquetas l_n contendo um intervalo máximo de k grupos correspondentes a cada observação n no espaço de recursos. Acelera-se o processo de filtragem ao

encontrar todos os blocos similares na janela de pesquisa ao mesmo tempo. Finalmente, calcula-se a média de cada grupo de blocos e retorna-se então o valor calculado para cada posição correspondente.

Nota-se que k pode ser entendido como uma função do tamanho da janela de pesquisa ω^2 . Quanto maior a janela de pesquisa ω , maior o número de blocos no espaço de recursos. Portanto, o processo de agrupamento requer uma ampla gama de k grupos. Neste trabalho, adota-se uma função linear $k = \omega$.

3- AGRUPAMENTO K-MEANS

Normalmente, o algoritmo *k-means* consiste em três etapas (Lloyd, 1982):

1) Inicialização: k centros dos grupos são escolhidos (Celebi et al., 2013). O presente algoritmo emprega uma abordagem hierárquica divisória. Começa por separar um grupo de todo o conjunto de observações. Para esse efeito, divide a dimensão que possui a maior variação. Então, a média e a variância dos dois grupos resultantes são computadas. O processo é repetido para k grupos.

2) Atribuição: as observações são atribuídas ao centro do grupo mais próximo, usando a métrica de distância euclidiana.

3) Atualização: os centróides dos grupos são atualizados.

O algoritmo itera as etapas 2 e 3 até que alguns critérios de parada sejam alcançados. Utiliza-se dois critérios de parada: o número máximo de iterações e a variação mínima na soma total de quadrados (TSS), i.e., a soma das distâncias quadradas das observações para seus respectivos grupos.

3- FILTRAGEM DE RUÍDO NO PROCESSAMENTO INTERFEROMÉTRICO SAR

Seja $\{C_1, C_2\}$ um par de imagens SLC (*Single Look Complex*) corregistradas. A imagem A é uma imagem SAR *multi-look* que é obtida de C_1 e é usada apenas para obtenção de blocos similares. Em seguida, mede-se os blocos correspondentes usando suas informações complexas originais em $\{C_1, C_2\}$. Isso resulta em um par de blocos complexos $\{C_1\}$ e $\{C_2\}$ usados para computar a fase filtrada ϕ , coerência ω e amplitude σ (Equações 3, 4 e 5).

$$\bar{\phi} = \arctg(\bar{C}_1 \bar{C}_2^*) \quad (3)$$

$$\bar{\omega} = \frac{|\sum \bar{C}_1 \bar{C}_2|}{\sqrt{(\sum |\bar{C}_1|^2)(\sum |\bar{C}_2|^2)}} \quad (4)$$

$$\bar{\sigma} = |\bar{C}_1| \quad (5)$$

4- METODOLOGIA

Esta seção contém uma descrição do conjunto de dados, a aquisição de medição de verdade terrestre e as métricas de avaliação.

1) Conjunto de dados SAR reais: uma área de 1400x900m (3600x2800 pixels) centrada nas coordenadas (-23,209757 lat; -45,961491 lon) foi escolhida perto das instalações de Bradar na cidade de São José dos Campos, adquirida em 17 de dezembro de 2015 pelo sensor OrbiSAR-2 na banda X. A largura de banda empregada foi de 400MHz em torno de uma frequência central de 9,55GHz, resultando em um comprimento de onda de 0,031m. Os vãos foram conduzidos a uma altitude de 1,5km com uma velocidade média de cerca de 92m/s, fornecendo uma resolução em *slant range* e em azimute de 0,37m e 0,29m, respectivamente. As imagens foram processadas de SLC para 11 looks.

2) Conjunto de dados SAR sintéticos: também gerou-se um conjunto de dados de 400x400 pixels que inclui amostras sem e com ruído adicionado. A Figura 1 mostra o exemplo de um interferograma de média zero obtido a partir de um par de SLCs sinteticamente gerados. No centro, o resultado é um quadrado com um deslocamento de fase de $\pi/2$. O interferograma ruidoso foi gerado com base em uma Distribuição Gama com nível de ruído (parâmetro de forma) $k = 1$, típico de imagens de aparência única.

3) Verdade de campo: 1015 pontos de controle de campo foram coletados na área de interesse usando o modo cinemático do GPS. Destes, 555 foram medidos em gramados homogêneos, enquanto 460 foram medidos nas estradas próximas.

4) Métricas de avaliação: para o conjunto de dados SAR real, empregou-se a diferença média e o desvio padrão da diferença entre os pontos de controle de campo e suas alturas medidas, o número de pontos superiores a um limiar de coerência τ (NP), e o tempo médio de execução. Para o conjunto de dados SAR sintéticos, empregou-se o número equivalente de looks (ENL) que mede a homogeneidade de uma área e a relação sinal-ruído de pico (PSNR) que mede a diferença entre uma imagem sem ruído x e a imagem filtrada x com N pixels.




Fig. 1 – (a) Um interferograma sem ruído (o quadrado central tem um deslocamento de fase de elevação de $\pi/2$); (b) O mesmo interferograma de (a) com adição de ruído de Distribuição Gama de nível de $k = 1$

$$PSNR = 20 \log_{10} \left(2\pi \sqrt{\frac{N}{\sum_i (\bar{x}_i - x_i)^2}} \right) \quad (6)$$

$$ENL = (\text{média})^2 / \text{variância} \quad (7)$$

5- RESULTADOS

Nesta seção, apresenta-se os resultados obtidos pelo Boxcar clássico (ou seja, um filtro médio móvel), NLSAR (o estado-da-arte) e a abordagem BMInSAR proposta. Todos os experimentos foram conduzidos em uma máquina Intel usando todas as 40 CPUs de 2,5GHz em paralelo e 378GB de memória RAM disponível.

Considerando-se o conjunto de dados SAR reais, a Tabela 1 apresenta a diferença média e desvio padrão dos experimentos feitos com o parâmetro ω em {8; 16; 32} metros, o que corresponde à aplicação de caixas de {27; 55; 91} pixels, respectivamente. Além disso, avaliou-se as mudanças do limiar de coerência ($\tau = \{0,2; 0,3; 0,4\}$). Observou-se claramente que o BMInSAR exibe valores de desvio padrão muito baixos, alcançando uma precisão de até 21cm para a área de gramado homogênea, que é quase duas vezes mais precisa do que a abordagem Boxcar clássica e também melhor do que o NLSAR. O mesmo comportamento foi observado para os pontos colocados na estrada, onde a abordagem proposta alcançou uma precisão de 1,12m (Tabela 2). Os valores de diferença de média na área do gramado são em torno de -20cm para todos os métodos que indicam um deslocamento residual do processo de calibração de fase. No entanto, os pontos colocados na estrada apresentaram uma discrepância positiva para o Boxcar, o que indica um viés por filtragem de objetos altos (por exemplo, árvores). O número de pontos superiores ao limiar de coerência pode ser analisado na Tabela 3. Observou-se que o método proposto detectou pontos ligeiramente menores em comparação com as outras abordagens para valores de limiar de coerência mais elevados (0,3; 0,4). Ainda assim, com baixos valores de coerência (0,2), o método proposto é capaz de fornecer um número razoável de pontos, ao mesmo tempo em que proporciona uma melhor precisão. A Tabela 4 demonstra a eficácia e a superioridade do BMInSAR para as medidas de avaliação clássicas de ENL e PSNR.

A Tabela 5 apresenta o tempo médio de execução para conjuntos dados SAR reais e sintéticos. Nas experiências, considerou-se o tempo médio de 5 execuções para cada abordagem. Evidentemente, a abordagem Boxcar é o algoritmo mais rápido devido à sua simplicidade. Em contraste, o NLSAR é muito mais lento, exigindo 1549min para cada execução. A abordagem BMInSAR é capaz de manter um tempo de execução razoável de 79min (com o parâmetro $\beta = 5$), mesmo empregando janelas de pesquisa maiores.

Visualmente, as saídas dos conjuntos de dados SAR sintéticos e reais nas Figuras 2 e 3 mostram o resultado de cada abordagem de filtragem com uma janela de busca de aproximadamente 32m. Os dados SAR reais incluem uma região de estradas, vegetação e uma área de gramado. Considerando-se que o Boxcar destrói completamente as imagens, as abordagens não locais são mais precisas na preservação das estruturas e bordas. No entanto, pode-se notar que o NLSAR não é preciso em algumas áreas homogêneas devido à presença de algum ruído residual, principalmente mais próximo de estruturas e regiões de baixa coerência. O BMInSAR fornece uma filtragem consideravelmente mais precisa e revela muito mais detalhes do que os outros métodos, incluindo áreas de baixa coerência.

TABELA 1 – Imagem SAR real – Média e Desvio Padrão no gramado

τ	w [m]	Boxcar	NLSAR	BMInSAR
0,2	8	$-0,208 \pm 0,351$	$-0,265 \pm 0,400$	$-0,286 \pm 0,342$
	16	$-0,196 \pm 0,373$	$-0,282 \pm 0,302$	$-0,254 \pm \mathbf{0,219}$
	32	$-0,162 \pm 0,429$	$-0,283 \pm 0,263$	$-0,246 \pm \mathbf{0,219}$
0,3	8	$-0,208 \pm 0,351$	$-0,251 \pm 0,424$	$-0,271 \pm 0,443$
	16	$-0,197 \pm 0,373$	$-0,258 \pm 0,367$	$-0,246 \pm 0,282$
	32	$-0,162 \pm 0,429$	$-0,264 \pm 0,338$	$-0,248 \pm \mathbf{0,218}$
0,4	8	$-0,208 \pm 0,355$	$-0,253 \pm 0,432$	$-0,274 \pm 0,440$
	16	$-0,197 \pm 0,373$	$-0,266 \pm 0,341$	$-0,243 \pm 0,315$
	32	$-0,162 \pm 0,429$	$-0,260 \pm 0,370$	$-0,248 \pm \mathbf{0,218}$

TABELA 2 – Imagem SAR real – Média e Desvio Padrão na estrada

τ	w [m]	Boxcar	NLSAR	BMInSAR
0,2	8	$1,240 \pm 2,799$	$-0,724 \pm 2,814$	$-0,707 \pm 2,370$
	16	$1,172 \pm 1,462$	$-0,429 \pm 2,521$	$-0,333 \pm 1,510$
	32	$1,899 \pm 1,391$	$-0,569 \pm 2,536$	$0,080 \pm \mathbf{1,264}$
0,3	8	$1,550 \pm 2,452$	$-0,340 \pm 2,167$	$-0,278 \pm 2,037$
	16	$1,306 \pm 1,316$	$-0,141 \pm 2,039$	$0,175 \pm 1,140$
	32	$1,900 \pm 1,391$	$-0,388 \pm 2,014$	$0,432 \pm \mathbf{1,118}$
0,4	8	$1,519 \pm 2,392$	$-0,111 \pm 1,960$	$0,029 \pm 1,839$
	16	$1,377 \pm 1,295$	$0,204 \pm 1,883$	$0,478 \pm 1,224$
	32	$1,903 \pm 1,393$	$0,070 \pm 1,810$	$0,697 \pm \mathbf{1,213}$

TABELA 3 – Número de pontos GPS válidos (NP) maiores que o limiar de coerência – gramado/estrada

τ	w [m]	Boxcar	NLSAR	BMInSAR
0,2	8	555 / 442	555 / 432	555 / 412
	16	555 / 452	555 / 438	555 / 386
	32	555 / 460	555 / 454	553 / 382
0,3	8	555 / 416	555 / 370	555 / 284
	16	555 / 434	555 / 368	555 / 262
	32	555 / 460	555 / 406	551 / 244
0,4	8	555 / 394	555 / 224	553 / 160
	16	555 / 416	553 / 232	553 / 144
	32	555 / 458	555 / 286	551 / 150

TABELA 4 – Imagem SAR sintética – ENL e PSNR [dB]

Métrica	Método	w [pix]		
		21x21	51x51	91x91
ENL	Boxcar	727,86	769,64	206,01
	NLSAR	29,88	28,72	34,09
	BMInSAR	297,68	1418,47	2980,20
PSNR	Boxcar	30,11	27,04	24,79
	NLSAR	26,73	26,51	27,19
	BMInSAR	35,69	39,16	39,51

TABELA 5 – Tempo médio de execução [min]

Dados	w [pix]	Boxcar	NLSAR	BMInSAR
Reais	27x27	6,80	37,07	7,01
	55x55	8,63	243,57	25,01
	91x91	18,10	1549,92	79,12
Sintéticos	21x21	0,05	2,35	0,54
	51x51	0,05	28,08	1,04
	91x91	0,05	166,53	3,54




Fig. 2 – Resultado da filtragem do conjunto de dados SAR sintético com uma janela de busca de 91x91 pixels: (a) Boxcar, (b) NLSAR e (c) BMInSAR




Fig. 3 – Esquerda: fase interferométrica [-2,1]; Centro: coerência [0,1]; Direita: amplitude [0,1]; Acima: Boxcar; Centro: NLSAR; Abaixo: BMInSAR; Detalhe da área de teste, incluindo estradas, gramados e alguma vegetação; Experiência realizada com uma janela de pesquisa de 91x91 pixels (32m)

6- CONCLUSÕES

Apresentou-se uma abordagem inovadora para a filtragem de ruídos na fase InSAR que supera substancialmente o estado-da-arte em termos de qualidade e tempo de execução. Utilizou-se um algoritmo *k-means* simples para otimizar o problema de busca de similaridade de bloco, típico de algoritmos de meios não locais. Além disso, propôs-se uma nova e rigorosa validação com verdade de campo dos resultados através da medição dos pontos de controle de campo com GPS que avaliam diretamente a precisão do processo geral de filtragem. A abordagem BMInSAR

revelou novos detalhes na fase interferométrica, alcançando uma precisão sem precedentes de 21cm no DEM resultante, que é semelhante àsquelas obtidas com a tecnologia LiDAR.

Os trabalhos futuros incluem a extensão do BMInSAR para considerar informações complexas (fase e amplitude) como critério de similaridade. Além disso, pretende-se realizar uma análise de espaço de parâmetros do método proposto, considerando diferentes abordagens de agrupamento e/ou funções de janela de pesquisa. Finalmente, planeja-se avaliar essa abordagem em outros conjuntos de dados, incluindo uma ampla gama de resoluções, dados de banda P e estruturas mais desafiadoras, como alturas de linha de energia.

REFERÊNCIAS BIBLIOGRÁFICAS

Barreto, T.L.M.; Almeida, J. e Cappabianco, F.A.M., 2016a. Estimating accurate water levels for rivers and reservoirs by using SAR products: A multitemporal analysis. Pattern Recognition Letter, Vol. 83, Nº 2, pp. 224-233.

Barreto, T.L.M.; Rosa, R.A.S.; Wimmer, C.; Nogueira, J.B.; Almeida, J. e Cappabianco, F.A.M., 2016b. Deforestation change detection using high-resolution multi-temporal X-Band SAR images and supervised learning classification, em IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Pequim, China, pp. 5201-5204.

Barreto, T.L.M.; Rosa, R.A.S.; Wimmer, C.; Moreira, J.R.; Bins, L.S.; Cappabianco, F.A.M. e Almeida, J., 2016c. Classification of detected changes from multitemporal High-Res Xband SAR images: Intensity and texture descriptors from superpixels. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 9, Nº 12, pp. 5436-5448.

Bashar, F., 2015, BM3D Image Denoising using Learning-Based Adaptive Hard Thresholding, Electronic Thesis and Dissertation Repository, The University of Western Ontario, Ontário, Canadá, 97 páginas.

Buades, A.; Coll, B. e Morel, J-M., 2004, On image denoising methods, CMLA Preprint, Vol. 5, Paris, França, 40 páginas.

Buades, A.; Coll, B. e Morel, J-M., 2005. A non-local algorithm for image denoising, em IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), San Diego, EUA, Vol. 2, pp. 60-65.

Celebi, M.E.; Kingravi, H.A. e Vela, P.A., 2013. A comparative study of efficient initialization methods for the k-means clustering algorithm. Expert Systems with Applications, Vol. 40, Nº 1, pp. 200-210.

Dabov, K.; Foi, A.; Katkovnikl, V. e Egiazarian, K., 2006. Image denoising with block-matching and 3d filtering, em Proceedings of SPIE Electronic Imaging, San Jose, EUA, Vol. 6064, Nº 30, pp.606414-606414.

Lloyd, S., 1982. Least squares quantization in PCM. IEEE Transactions on Information Theory, Vol. 28, Nº 2, pp. 129-137.