

Comparação entre o uso de filtros e classificadores em uma imagem de radar, em ambiente SPRING

Taís Virgínia Gottardo¹
Carlos Antônio Oliveira Vieira¹

¹Universidade Federal de Viçosa - UFV
Departamento de Engenharia Civil - DEC
Setor Engenharia de Agrimensura, Viçosa - MG
taisvgottardo@yahoo.com.br; carlos.vieira@ufv.br

Abstract. In this present paper, the stages of filtering and classification were performed with help of software SPRING. For the classification of the polarized image, were considered three land cover classes: forest, urban and agricultural area. Different filters were used, as the mean, Kuan, Frost and Lee filters, as well as different window size. There was supervised classification with the classifiers of Maximum Likelihood, Maximum Likelihood – Iterated Conditional Modes (ICM), and Bhattacharyya distance. For the comparison between the performance of the filters, was studied the reduce of the variance obtained after the use of each filter. For the evaluation of the performance of the classifiers was used the kappa coefficient, and its variance. The comparison between the filters showed better results to filters of adaptive window size, suitable for radar images. In the comparison between the classifiers was observed that the results obtained by the Bhattacharyya distance were the best confidence level of 95%. However, the techniques evaluated and compared did not show good results, 0.488 was the highest value found for Kappa, indicating the need for more research for the processing of radar images and implementing new techniques that consider the particularities of this type of image.

Palavras-chave: adaptive filters, classification, segmentation images, SPRING, filtros adaptativos, classificação, segmentação de imagens, SPRING.

1. Introdução

O uso das imagens de radar ainda está limitado pela falta de técnicas que considerem suas particularidades, como os ruídos e suas distorções geométricas. Entre as principais distorções presentes em imagens de radar, existem os deslocamentos de relevo e as distorções radiométrica para as quais se destaca o ruído *speckle*.

O ruído *speckle* tem como causa o fato de que na faixa de microondas a radiação interage com a superfície de maneira variável para as superfícies mais lisas até as mais rugosas, podendo sofrer reflexão difusa, especular ou de canto. As interferências locais podem ser construtivas ou destrutivas no sinal retroespalhado (BENTZ, 2006).

O modelo *speckle* assume que cada célula de resolução é composta por diferentes sinais retroespalhados por um mesmo alvo constituído por inúmeros refletores independentes. Assim, o valor do nível de cinza de um *pixel* é resultado de uma soma vetorial das diferentes amplitudes e fases (GABOARDI, 2002).

Recomenda-se, para imagens de radar, processamento com filtros adaptativos, que são os filtros que consideram as propriedades do retroespalhamento ou da natureza do sensor. Um filtro ideal para redução de *speckle* deve preservar o máximo de informação da imagem original, conservando as bordas para áreas homogêneas e preservando a variabilidade espacial para área com textura (CCRS, 2008).

Esse trabalho tem como objetivo, comparar o desempenho de filtros e classificadores no processamento de imagens de radar de maneira a contribuir com a inclusão dos sistemas sensores ativos, difundindo os trabalhos nessa área e aumentando o número de usuários e aplicações destas imagens.

2. Materiais e métodos

2.1 Caracterização da área de estudo

A área de estudo é localizada no nordeste da Alemanha, em uma região fortemente marcada pela agricultura. É compreendida entre as coordenadas geográficas 13°13'18" e 13°15'42" de longitude Leste e 53°59'10" e 54°00'16" de latitude Norte (Figura 1).

A imagem utilizada representa uma área de 9,07 km². A imagem foi adquirida em maio de 2006. É uma imagem sub-orbital do sensor E-SAR e que registra comprimentos de onda na banda C. Possui polarização HH, VV e HV, correspondente às bandas do vermelho, verde e azul, respectivamente. A resolução espacial é de 4,0m x 2,2m (MICROWAVES AND RADAR INSTITUTE, 2008).

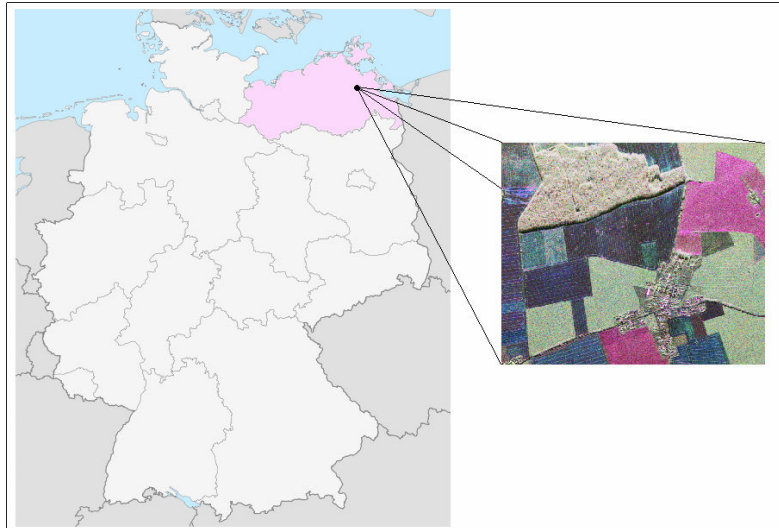


Figura 1. Localização da área de estudo.

2.2 Metodologia

A primeira etapa do trabalho foi a utilização dos filtros de Lee, de Frost e de Kuan, que são filtros específicos para imagens de radar, como também a utilização do filtro passa-baixa da média. Para o processamento das imagens foi utilizado o *software* SPRING.

O filtro de Frost é derivado da minimização do erro médio quadrático sobre o modelo multiplicativo do ruído, onde a dependência estatística do sinal original é incorporada. É um filtro adaptativo e que preserva a estrutura de borda (INPE, 2004). Para o filtro de Frost o valor \hat{I} associado ao *pixel* corrente é dado pela Equação (1):

$$\hat{I}(x, y) = \sum_i \sum_j m(x+i, y+i) I(x+i, y+i) \quad (1)$$

Na Equação (1), x e y determinam a posição do *pixel* corrente e i e j são determinados pelos limites da janela do filtro. O coeficiente $m(x+i, y+i)$ é dado pela Equação (2):

$$m(x+i, y+i) = K_0 \alpha \exp(-\alpha t); \quad (2)$$

Onde: α é o coeficiente adaptativo determinado por estatísticas locais da janela;

K_0 é a constante normalizadora;

t é a distância entre o *pixel* corrente (x,y) ao *pixel* na posição $(x+i,y+i)$.

O filtro de Lee estima o valor de um *pixel* através da soma ponderada do valor do *pixel* central e da média. A ponderação considerada é obtida como uma função da heterogeneidade dos sinais que compõe o valor do *pixel*. É um filtro adaptativo e geral. O valor \hat{x} do *pixel* corrente (x,y) é associado pelo filtro de Lee, de acordo com a Equação (3):

$$\hat{x} = \bar{x} + k(z - \bar{x}) \quad (3)$$

Onde: \bar{x} = média local da janela;

z = valor do *pixel* corrente;

k = coeficiente adaptativo entre 0 e 1.

O filtro de Kuan também é um filtro adaptativo e geral que se diferencia do filtro de Lee apenas por uma pequena diferença no cálculo de k .

As imagens foram submetidas ao filtro de Lee com janelas de tamanho adaptativo e fixo de 3×3 pixels, 5×5 pixels, 7×7 pixels e 9×9 pixels. Para o filtro de Kuan considerou-se apenas janela de tamanho adaptativo, pois para tamanhos fixos o filtro de Kuan é idêntico ao filtro de Lee. Para o filtro de Frost foi considerada apenas a janela de tamanho adaptativo. Para o filtro da média foram consideradas as janelas de tamanho fixo com 5×5 pixels e 7×7 pixels.

Após o uso dos filtros, as imagens filtradas e a imagem original foram classificadas utilizando 3 classificadores, sendo eles: classificador de máxima verossimilhança, classificador de máxima verossimilhança com modas condicionais iterativas e classificador por distância de *Bhattacharyya*. Esses classificadores serão aqui chamados de MV, MV-ICM e *Bhattacharyya*, respectivamente.

O classificador MV-ICM é uma adaptação do classificador MV. MV-ICM é um classificador contextual e iterativo. Na “iteração inicial” usa-se o algoritmo MV. A partir de então, substitui-se, a cada iteração, a classe associada a cada *pixel* pela classe que maximiza a distribuição de probabilidade *a posteriori*. As iterações cessarão quando atingir o nível de convergência determinado ou o número máximo de iterações (GABOARDI, 2002).

Para a classificação das imagens foram consideradas as classes mata, área urbana e área agrícola.

Para os classificadores MV e MV-ICM foram consideradas sempre as mesmas amostras de treinamento, representadas na Figura 2. Sendo assim, a influência do treinamento será igual para todas as classificações por *pixel*, garantindo, assim a validade da comparação entre os classificadores.




Figura 2. Indicação dos locais das amostras de treinamento das classes mata, área urbana e área agrícola, utilizadas nas classificações por MV e MV-ICM.

Foram amostrados *pixels* em número suficiente para cada classe, permitindo que estimativas precisas dos parâmetros dessas classes fossem obtidos. Swain e Davis (1978) recomendam um número superior a 100 *pixels* amostrados para cada classe.

Na classificação MV-ICM foi considerado 15% de mudança, ou seja, as iterações cessaram quando 15% ou menos dos *pixels* receberem novas classes a partir da classificação por MV.

Para a classificação pelo algoritmo por distância de *Bhattacharyya*, primeiramente realizou-se a segmentação das imagens filtradas e da imagem original, considerando-se o limiar de 10 níveis de cinza para similaridade e de 36 *pixels* para área.

Para o treinamento do classificador, neste caso, as amostras não foram sempre as mesmas, uma vez que as amostras se tratam de regiões obtidas das imagens segmentadas e, as imagens segmentadas obtidas são diferentes para cada tipo de filtro aplicado.

Para a classificação por região o número de amostras por classe também foi diferente. Mather (2003) recomenda um número de 30 amostras por banda, para cada classe. Sendo assim, foram consideradas 90 regiões como amostras para cada classe.

Foram geradas, ao final dessa etapa, um total de 27 classificações ([1 original + 8 filtradas] x [3 classificadores]). Optou-se por não realizar a classificação da imagem filtrada pelo filtro de Kuan pois esta era idêntica a imagem filtrada pelo filtro de Lee, conforme será mostrado nas Tabelas 1, 2 e 3.

2.2.1 Análise dos resultados

Para posterior análise do desempenho dos filtros, para cada classe considerada, foram extraídas estatísticas de uma janela amostral de um conjunto 10.000 *pixels*.

A análise do desempenho dos filtros foi feita através da comparação da variância da imagem filtrada com a variância da imagem original (sem-filtro), comparando-se a variância em cada banda e a partir de janelas amostrais de cada classe. Para essa comparação utilizou-se o teste *F* obtido pelo resultado da divisão da variância correspondente à imagem filtrada pela variância correspondente à imagem original, em cada banda.

Para a análise dos classificadores foram considerados, como referência, 1000 *pixels* distribuídos aleatoriamente sobre a imagem. Dessa maneira obteve-se o coeficiente de concordância *Kappa* para cada classificação. Considerou-se o coeficiente de concordância *Kappa* por se tratar de um estimador amplamente utilizado em análises de classificações.

Com auxílio do *software* KAPPA (VIEIRA, 2000) comparou-se o desempenho dos 3 classificadores através do teste de hipótese *z*, a um nível de significância de 5%,.

3. Resultados e discussões

3.1 Redução do ruído *speckle*

Conforme apresentado nas Tabelas 1, 2 e 3, os filtros de Lee e Kuan apresentaram valores idênticos de *F* para todas as bandas e classes.

Tabela 1. Valores de *F** para a classe “mata”.

Tipo de Filtro	Banda	Tamanho da janela				
		adaptativo	3x3	5x5	7x7	9x9
Lee	1	0.327171	0.772419	0.560773	0.419295	0.327171
	2	0.349247	0.774228	0.575133	0.440983	0.349247
	3	0.353256	0.77401	0.571023	0.439354	0.353256
Frost	1	0.878901	---	---	---	---
	2	0.870215	---	---	---	---
	3	0.869062	---	---	---	---
Kuan	1	0.32717	---	---	---	---
	2	0.34925	---	---	---	---
	3	0.35326	---	---	---	---
Média	1	---	---	0.560773	0.419354	---
	2	---	---	0.575111	0.441017	---
	3	---	---	0.571125	0.439327	---

* $F = \text{var. imagem filtrada} / \text{var. imagem original}$

Tabela 2. Valores de F para a classe “área urbana”.

Tipo de Filtro	Banda	Tamanho da janela				
		adaptativo	3x3	5x5	7x7	9x9
Lee	1	0.403505	0.803953	0.629208	0.50434	0.403505
	2	0.376941	0.782676	0.596105	0.467988	0.376292
	3	0.469821	0.815859	0.65886	0.548684	0.469288
Frost	1	0.856551	---	---	---	---
	2	0.838357	---	---	---	---
	3	0.869953	---	---	---	---
Kuan	1	0.40351	---	---	---	---
	2	0.37694	---	---	---	---
	3	0.46982	---	---	---	---
Media	1	---	---	0.603973	0.457381	---
	2	---	---	0.568615	0.415724	---
	3	---	---	0.615542	0.464887	---

Tabela 3. Valores de F para a classe “área agrícola”.

Tipo de Filtro	Banda	Tamanho da janela				
		adaptativo	3x3	5x5	7x7	9x9
Lee	1	0.137799	0.647922	0.366998	0.216353	0.137799
	2	0.160898	0.655568	0.384002	0.239743	0.160898
	3	0.190541	0.655419	0.395982	0.262099	0.190541
Frost	1	0.827851	---	---	---	---
	2	0.815963	---	---	---	---
	3	0.784276	---	---	---	---
Kuan	1	0.1378				
	2	0.1609				
	3	0.19054				
Media	1	---	---	0.367118	0.216393	---
	2	---	---	0.384089	0.239639	---
	3	---	---	0.39608	0.262148	---

Da análise dos resultados obtidos, constatou-se a similaridade entre os filtros de Lee e Kuan, refletindo que a diferença no cálculo do coeficiente adaptativo k não foi expressiva.





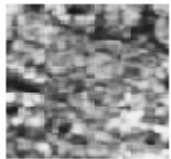



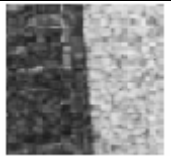


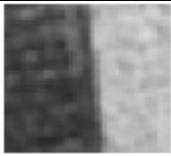
O filtro de média, em comparação com o filtro de Lee com mesmo tamanho de janela apresentou resultados muito semelhantes na redução do ruído *speckle*.

O filtro de Frost, apesar de ser um filtro específico para imagens de radar, apresentou os piores desempenhos, no que tange a redução da variância da imagem original.

Os melhores resultados foram encontrados para os filtros de Lee e Kuan com tamanho de janela adaptativo e 9x9 *pixels*. Nota-se que os resultados foram praticamente os mesmos para janelas de tamanho adaptativo e tamanho 9x9 *pixels*, não sendo possível indicar um melhor resultado entre os dois tamanhos.

A Tabela 4 apresenta uma comparação entre amostras das classes mata, área urbana e área agrícola. A partir dessa tabela é possível perceber visualmente o melhor desempenho do filtro de Lee com tamanho de janela adaptativo. Nota-se também que o resultado de redução do ruído *speckle* obtido com o filtro de média foi melhor do que o resultado obtido pelo filtro de Frost.

Tabela 4. Comparação entre amostras das classes mata, área urbana e área agrícola para os filtros de Lee, de Frost e da Média.

		Original	Tipo de filtro		
			Lee-adaptativo	Frost-adapativo	Média 7x7
Classes	Mata				
	Área urbana				
	Área agrícola				

Apesar dos valores calculados de F serem muito próximos para o filtro de Lee e o filtro da média, o filtro de Lee é mais adequado por ter a característica de preservar estruturas de borda, conforme pode ser visto na Tabela 4.

3.2 Classificação

A Tabela 5 apresenta os resultados para os classificadores MV, MV-ICM e o classificador por distância de *Bhattacharyya*. São também apresentados os valores dos coeficientes de concordância *Kappa* e sua variância.

Todas as classificações por MV e MV-ICM não foram estatisticamente diferentes ao nível de confiança de 95%.

Gomes (2007), ao comparar os classificadores MV e MV-ICM também não obteve resultados estatisticamente diferentes ao nível de confiança de 95%.

Tabela 5. Resultado da classificação pelo algoritmos MV, MV-ICM e *Bhattacharyya*.

Classificador	Tipo do Filtro	Tam. Janela	KAPPA	VAR
MV	*	--	0.245	0.0004
	Lee	adaptativo	0.317	0.0005
	Lee	3x3	0.266	0.0004
	Lee	5x5	0.276	0.0004
	Lee	7x7	0.302	0.0004
	Lee	9x9	0.317	0.0005
	Frost	adaptativo	0.271	0.0004
	Media	5x5	0.286	0.0004
	Media	7x7	0.31	0.0004
MV-ICM	*	--	0.262	0.0004
	Lee	adaptativo	0.316	0.0005
	Lee	3x3	0.266	0.0004
	Lee	5x5	0.284	0.0004
	Lee	7x7	0.304	0.0004
	Lee	9x9	0.316	0.0005
	Frost	adaptativo	0.267	0.0004

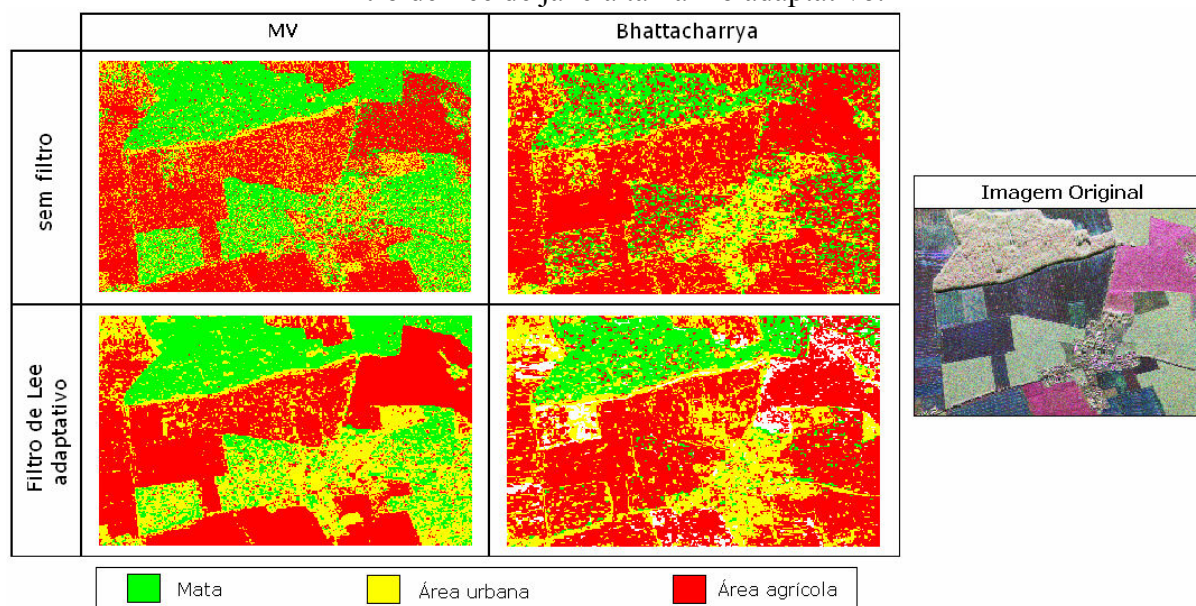
	Media	5x5	0.286	0.0004
	Media	7x7	0.314	0.0004
<i>Bhattacharrya</i>	*	--	0.350	0.00056
	Lee	adaptativo	0.488	0.000603
	Lee	3x3	0.454	0.000656
	Lee	5x5	0.437	0.000574
	Lee	7x7	0.435	0.000563
	Lee	9x9	0.487	0.000613
	Frost	adaptativo	0.465	0.000654
	Media	5x5	0.477	0.000641
	Media	7x7	0.475	0.000617

* imagem original

Ainda considerando o teste de hipótese realizado, para todas as classificações, o classificador por distância de *Bhattacharrya* apresentou melhores resultados.

A Figura 3 apresenta o resultado da classificação da imagem sem filtro (original) e da imagem filtrada por filtro de Lee de tamanho adaptativo, pelos classificadores MV e por distância de *Bhattacharrya*.

Figura 3. Classificação por MV e *Bhattacharrya* da imagem original e imagem filtrada por filtro de Lee de janela tamanho adaptativo.



A classe “área urbana” apresentou maior erros de concessão, em todos os casos. Ou seja, entre os *pixels* classificados como “área urbana”, na verdade, muitos deles pertenciam a outras classes. Para o classificador MV, os maiores erros de omissão também foram encontrados na classe “área urbana”. Sendo assim, dos *pixels* que deveriam ser classificados como “área urbana”, muitos receberam classes “mata” ou “área agrícola”.

A classe “área urbana” foi, em geral, a classe que apresentou maior confusão. Isso pode ser atribuído a menor homogeneidade desta classe.

Para o classificador por distância de *Bhattacharrya* os maiores erros de omissão foram encontrados para a classe “área agrícola”.

4. CONCLUSÕES

A partir dos resultados obtidos, pode-se concluir:

- o uso de filtros melhorou a qualidade da classificação das imagens, evidenciando a importância do uso de filtros antes da classificação de imagens de radar para a eliminação do ruído *speckle*, dando mais homogeneidade às classes;
- os filtros de Lee e Kuan apresentaram os mesmos resultados no presente estudo, o que impossibilitou indicar um filtro preferencial;
- em geral, o efeito de suavização de ruídos na imagem resultante foi tanto maior, quanto maior o tamanho da janela considerada;
- o filtro de Lee com janelas de tamanho adaptativo e tamanho 9×9 *pixels* apresentaram os melhores desempenhos na redução do ruído *speckle*. Porém apresentaram resultados muito semelhantes, não sendo possível indicar um melhor resultado entre os dois tamanhos de janela;
- o filtro de Frost, apesar de ser um filtro específico para imagens de radar não apresentou bons resultados no que tange a redução de ruídos;
- pode-se indicar, além do filtro de Lee, o filtro da média, para processamento de imagens de radar;
- Os classificadores MV e MV-ICM apresentaram os mesmos resultados a partir do teste de hipótese z , a um nível de significância de 5%;
- Os maiores valor de *Kappa* encontrados foram para o classificador por distância de *Bhattacharya*;

Nenhuma das classificações apresentou bom resultado, indicando a necessidade da execução de maiores estudos sobre imagens de radar e aperfeiçoamento das técnicas de processamento que considerem as características específicas dessas imagens.

Referências Bibliográficas

Bentz, C.M. **Reconhecimento Automático de Eventos Ambientais Costeiros e Oceânicos em Imagens de Radars Orbitais**. 2006. Tese (Doutorado em Ciências em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

CCRS, *Canada Centre for Remote Sensing – Radar Remote Sensing*. Tutorial. Retirado de: http://ccrs.nrcan.gc.ca/resource/tutor/gsarcd/index_e.php. Acessado em: 18/08/2008.

Gaboardi, C. **Utilização de imagem SAR para classificação do uso da terra: Floresta Nacional do Tapajós**. 2002. 137p. Dissertação (Mestrado) - Curso de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2002.

Gomes, A. R.; Freitas, C.C.; Sant'Anna, S.J.S.; Dutra, L.V. **Influência do georreferenciamento na classificação de imagem JERS-1**. In: Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 4879-4887.

INPE. SPRING: Sistema de Processamento de Informações Georreferenciadas. **Manual de ajuda**, 2004.

Mather, P. M. **Computer Processing of Remotely-Sensed Images: An Introduction**. John-Wiley and Sons, Chichester, The Third Edition, 2003.

Microwaves and Radar Institute. Disponível em http://www.dlr.de/hr/en/desktopdefault.aspx/tabid-4698/7782_read-12248/. Acesso em: 24/09/2008.

Swain, P.H.; Davis, S.M. **Remote Sensing: the quantitative approach**. New York: McGraw-Hill, 1978. 396p.

Vieira, C.A.O.; Mather, P.M.; McCullagh, M. **The Spectral-Temporal Response Surface and its use in the multi-sensor, multi-temporal classification of agricultural crops**. In ISPRS: IAPRS, Vol. XXXIII, Part B2, Amsterdam, The Netherlands, 16-23 July 2000, p. 582-589.