

CLASSIFICAÇÃO DE DADOS DE RADAR NA BANDA-P UTILIZANDO REDE NEURAL ARTIFICIAL PARA MAPEAMENTO DE COBERTURA DA TERRA NA REGIÃO DE SANTARÉM, PARÁ.

ALCINA MARIA NEPOMUCENO¹
DALTON DE MORISSON VALERIANO¹
CORINA DA COSTA FREITAS²
ANTÔNIO NUNO DE CASTRO SANTA ROSA³
NILTON CORREIA DA SILVA⁴
JOÃO ROBERTO DOS SANTOS¹
LUCIANO VIEIRA DUTRA²

Instituto Nacional De Pesquisas Espaciais – INPE
Av. dos Astronautas 1758
12201-970 - São José dos Campos - SP, Brasil

¹Divisão de Sensoriamento Remoto – DSR
(alcina, dalton, jroberto)@ltid.inpe.br

²Divisão de Processamento de Imagens – DPI
(corina, dutra)@dpi.inpe.br

Universidade de Brasília
Campus Universitário Darcy Ribeiro - Asa Norte
70910-900 - Brasília - DF – Brasil

³Deptº da Ciência da Computação
(nuno@cic.unb.br)

⁴Instituto de Geociências
niltoncs@unb.br

Abstract. The present work is concerned with the potential application of artificial neural networks for the classification of polarimetric radar images operating in the P band. The study area is located near the Tapajós National Forest, in the northern State of Pará, Brazil, and comprises regions of dense rain forest partially disturbed by deforestation and agricultural land use. The remote sensing data were obtained during the test mission of the polarimetric imaging radars (P (415 MHz) and X (10 GHz) bands) of the German company AeroSensing RadarSystem GmbH, promoted by the Brazilian Army and the National Institute for Space Research in September 2000. A P band 2.4 km x 7.4 km- image was selected to assess the capacity of the neural network "Fuzzy-ART" for the land cover classes discrimination. Two time-domain filtering processes were compared regarding their ability to reduce the speckle noise, both of them operating with neighborhood boxes of three and five cells. Filtered and non-filtered HH, HV as well VV P band images were used as inputs by the network to generate classified images. A confusion matrix based on ground truth data was employed for the global and partial classification accuracy analysis, which considered seven land cover classes: exposed soil (IF), pasture/tillage (PC), recent forest regeneration (RN), intermediate forest regeneration (RI), old forest regeneration (RA), very old forest regeneration (RMA), and primary forest (FP). The results show that the unsupervised neural network-based classification method was able to accordingly map the land cover classes in respect to the field observations samples. The results point to prospective use of data and classification methodology for fast and accurate radar images interpretation, complying with the needs of ongoing monitoring and fiscalization activities in the dense rain forest in a quick and efficient manner.

Keywords: radar, classification, Artificial Neural Networks, land cover.

1. Introdução

Dados polarimétricos de radar vêm sendo utilizados em estudos de mapeamento de cobertura da terra, em escala global e regional, principalmente em regiões de florestas tropicais úmidas onde trabalhar com dados ópticos é dificultado em virtude da grande cobertura de nuvens presente nestas áreas. Além disto, o radar provê uma fonte de dados em larga escala. O papel chave no monitoramento é o preenchimento de intervalos entre dados causados pela falta de disponibilidade de imagens ópticas (Leckie & Ranson, 1998). Neste contexto, processos de classificação automáticos e não-supervisionados são essenciais quando a operação tempo/dependência são empreendidas. Nestes casos, as Redes Neurais surgem como uma importante ferramenta no processamento automático dos dados de sensoriamento remoto de modo rápido e preciso. Pesquisas mais recentes têm utilizado técnicas de Inteligência Artificial para reconhecimento de padrões e classificação de imagens orbitais (Ribeiro & Centeno, 2001). Sucessivas aplicações de Inteligência Artificial em classificação de imagens de Sensoriamento Remoto têm sido registradas na literatura, mostrando que as redes neurais artificiais são capazes de alcançar resultados comparáveis ou, até mesmo, superiores aos das abordagens estatísticas convencionais (Gonçalves *et al.*, 1998).

Os principais objetivos deste trabalho consistem em estudar a capacidade discriminatória da banda-P para o mapeamento de cobertura da terra, e a utilização de uma nova metodologia na classificação destes dados usando a rede auto-organizativa, Fuzzy-ART, gerenciada por um algoritmo genético (AG), que de acordo com Silva & Santa Rosa, (2002) o AG é um método de busca não aleatório que pode ser muito útil para estimar os melhores parâmetros de entrada da rede, ou seja, existe uma população genética que representa amostras dos parâmetros de entrada que serão aperfeiçoados por operadores genéticos a fim de melhorar a estrutura neural, e conseqüentemente o processo de classificação das imagens.

2. Área de Estudo

A área escolhida está localizada entre as coordenadas planas 729460.000E 9662519.499N e 731832.500E 9655139.499N, projeção UTM zona 21 sul, Datum SAD/69 Brasil. Situada no estado do Pará ao longo da rodovia BR 163 Cuiabá/Santarém e inclui os arredores do povoado de São Jorge.

3. Dados AIRSAR

As imagens utilizadas neste trabalho foram obtidas em setembro de 2000 pela Agência Aeroespacial da Alemanha (DLR - Deutsches Zentrum für Luft-und Raumfahrt e.V) a partir da missão teste do AeroSensing RadarSystem GmbH (radar aerotransportado de visada lateral), polarimétrico, ou seja, várias polarizações (HH, HV, VH, VV), na Banda P, com um comprimento de onda de 72 cm e frequência de 415 MHz, e com um ângulo de incidência variando de 29° (near range) a 55°(far range).

4. Redução do ruído speckle

Como parte da metodologia adotada neste trabalho utilizamos os filtros citados por Nepomuceno (2000) e Santa Rosa & Meneses (1999) com a finalidade de reduzir a quantidade de ruído “speckle” presente nas imagens de radar.

Após o processo de filtragem, foram testados os desempenhos dos filtros e dos tamanhos, 3x3 e 5x5, das janelas. Para este objetivo utilizamos a técnica da relação sinal/ruído (SNR) descrita em Schowengerdt (1997).

4.1. Relação sinal/ruído

Embora uma avaliação qualitativa possa parecer satisfatória visualmente, ela pode ser considerada não muito precisa quando se pretende avaliar corretamente o resultados de uma filtragem. Algumas medidas das quantias relativas de sinal e ruído são necessárias. A SNR é uma destas medidas e foi analisada separadamente para cada alvo presente na imagem devido à natureza multiplicativa do ruído “speckle”, ou seja, este se apresenta mais intenso em regiões da imagem onde a intensidade de retorno do sinal é maior.

5. Classificação

A classificação foi do tipo não-supervisionada, pixel a pixel, utilizando a rede auto-organizativa, Fuzzy-ART que utiliza o critério de similaridade para a escolha do agrupamento (cluster) a que um determinado pixel pertence. Os parâmetros da rede são otimizados por um algoritmo genético. O algoritmo genético (AG) é um método de busca não aleatório que pode ser muito útil na escolha dos parâmetros que resultam numa melhor estrutura neural, e conseqüentemente numa melhor classificação.

Foi utilizado o programa (OEER) desenvolvido por Silva (2002) em sua tese de Doutorado. O mesmo funciona com três diferentes tipos de redes e junto a estas um algoritmo genético que permite a otimização dos resultados da rede neural, para cada problema. Utilizamos basicamente a rede Fuzzy-ART, pois a mesma apresentou-se mais sensível (separou melhor os agrupamentos) para este tipo de dado. As classificações foram feitas usando como entrada para a rede as imagens de radar polarimétrico na banda P, ou seja, as polarizações HH, HV e VV originais (sem filtragem), e filtradas.

6. Exatidão das imagens classificadas

A exatidão foi feita utilizando-se o método da tabulação cruzada que consiste em cruzar os padrões das imagens classificadas com as amostras das classes de verdade de campo. Os principais tipos de cobertura da terra identificados em campo foram: solo exposto (SE), pasto/cultura (PC), regeneração nova (RN), regeneração intermediária (RI), regeneração antiga (RA), regeneração muito antiga (RMA) e floresta primária (FP). Foram utilizados dois conjuntos de amostras das classes de verdade de campo, um para identificar e combinar os padrões em relação às classes, e outro para realizar a análise de exatidão global. Os padrões presentes nas imagens classificadas foram relacionados às classes através da quantidade de pixels de cada padrão em relação à quantidade de pixels das amostras das classes. Desta forma, podemos identificar quais padrões foram mais representativos em relação a cada classe, e a partir desta análise combinar os padrões mais representativos para uma determinada classe e assim sucessivamente, conforme apresentado nas Tabelas 1, 2, e 3. Após atingir um número de padrões iguais ao número de classes de verdade de campo, gerou-se novamente uma matriz de confusão, conforme Tabelas 4, 5 e 6, utilizando o outro conjunto de amostra das classes de verdade de campo, e junto às exatidões por classes e a exatidão global.

7. Resultados e Discussões

7.1. Redução do ruído “speckle”

Conforme Gráfico 1 observamos que para a seqüência de filtragem com os filtros Frost e Mediana a janela de tamanho 3x3 apresentou um melhor resultado na redução do ruído speckle. De acordo com o Gráfico 2, a janela de tamanho 5x5 apresentou o melhor resultado para filtro Map-gamma. E, o Gráfico 3, mostra a comparação dos melhores

resultados entre os dois processos de filtragem, o filtro Map-gamma obteve um melhor resultado em relação à sequência Frost e Mediana. Porém, esta é uma análise geral, dado que as classes apresentaram uma SNR diferentemente entre si, bem como uma resposta diferenciada em relação ao tipo de imagem utilizada, ou seja, a polarização analisada.

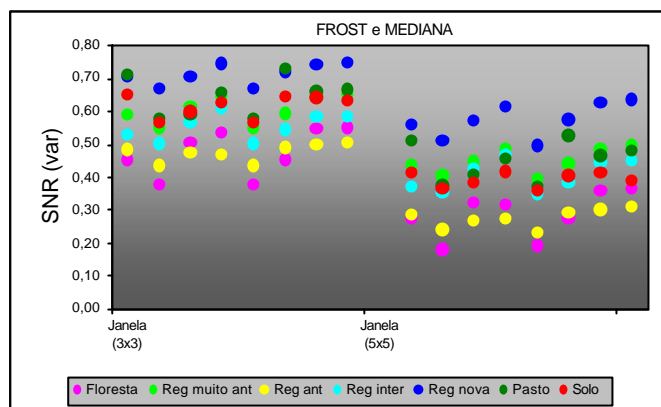


GRÁFICO 1- COMPARAÇÃO DO DESEMPENHO DOS TAMANHOS DAS JANELAS DOS FILTROS FROST E MEDIANA

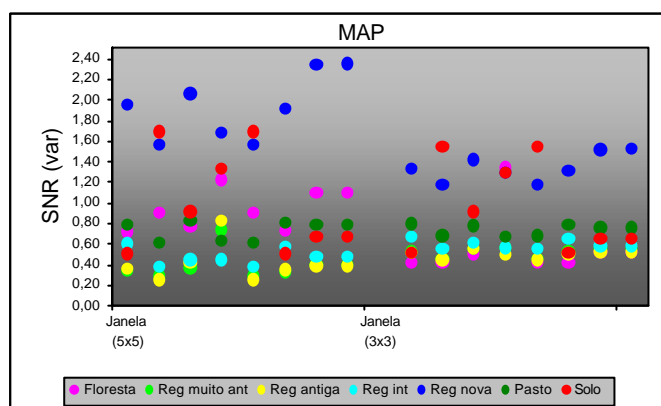


GRÁFICO 2- COMPARAÇÃO DO DESEMPENHO DOS TAMANHOS DAS JANELAS DO FILTRO MAP-GAMMA.

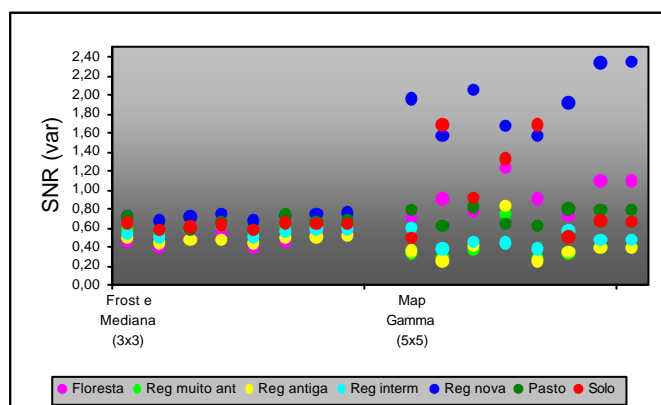


GRÁFICO 3- COMPARAÇÃO DO DESEMPENHO DOS FILTROS.

7.2. Classificação

Como resultado das classificações das polarizações HH, HV e VV apresentadas simultaneamente à rede, obtivemos para as imagens originais 16 padrões, para as

imagens filtradas, com Frost e Mediana (3x3), 15 padrões, e para as imagens filtradas, com Map-gamma (5x5), 12 padrões.

De acordo com as Tabelas 1, 2 e 3, observamos que houve uma grande confusão entre as classes muito próximas em relação à quantidade de sinal retroespalhado, por exemplo, as classes SE e PC têm alta porcentagem de confusão entre si, o que já era esperado, ou seja, estas classes não são possíveis de serem separadas a partir de dados com comprimento de onda muito longo. As classes FP e RMA; RN e RI, também apresentaram comportamentos semelhantes. Os padrões marcados com a mesma cor representam que estes são mais representativos para uma determinada classe. A partir desta identificação combinou-se destes padrões entre si, e atribuiu-se a cada padrão o nome da sua respectiva classe, e os valores da diagonal principal representam a exatidão por cada classe, que variou de acordo com o tipo de filtro utilizado no pré-processamento das imagens, como mostrado nas tabelas 4, 5, e 6.

TABELA 1 – PORCENTAGEM DE PIXEL DOS PADRÕES ENCONTRADOS PELA REDE EM RELAÇÃO AOS PIXELS DAS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV ORIGINAIS.

Class.	6	0	15	7	11	4	10	9	13	5	14	1	8	2	12	3
SE	88,55	3,38	0,09	0,56	0,03	4,68	0,10	0,42	1,35	0,06	0,04	0,04	0,05	0,54	0,06	0,04
PC	67,49	5,24	0,12	1,68	0,21	17,72	0,49	1,24	2,60	0,29	0,25	0,09	0,24	1,92	0,27	0,17
RN	10,25	1,79	0,02	12,39	2,84	46,94	8,99	3,27	4,87	2,45	1,43	1,18	0,78	1,84	0,70	0,26
RI	10,92	2,38	0,05	9,99	2,14	48,30	4,96	5,32	7,53	2,32	2,18	0,79	0,36	2,29	0,19	0,27
RA	1,70	0,93	0,04	9,89	2,62	19,43	13,24	7,88	11,74	7,34	5,50	4,51	2,95	8,41	1,45	2,38
RMA	1,73	0,58	0,03	5,61	1,87	12,47	11,31	6,95	9,43	6,80	5,09	6,58	10,39	11,96	2,94	6,26
FP	1,16	0,49	0,07	4,77	1,20	9,16	11,48	3,81	6,66	4,55	2,35	6,73	18,79	13,36	7,13	8,29

TABELA 2 – PORCENTAGEM DE PIXEL DOS PADRÕES ENCONTRADOS PELA REDE EM RELAÇÃO AOS PIXELS DAS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV FROST E MEDIANA.

Class	9	6	3	4	5	11	10	12	14	8	2	0	7	1	13
SE	92,97	0,58	2,90	0,01	1,29	1,25	0,33	0,06	0,00	0,35	0,15	0,01	0,02	0,04	0,03
PC	65,91	0,24	8,60	0,06	5,74	12,08	2,98	0,33	0,17	1,99	0,96	0,24	0,07	0,40	0,23
RN	0,73	0,00	3,65	4,84	8,92	46,64	12,21	10,98	3,98	1,83	3,06	0,84	0,61	0,17	1,53
RI	0,36	0,00	2,31	1,58	10,26	48,68	21,87	4,11	2,60	2,22	3,72	1,23	0,30	0,27	0,47
RA	0,00	0,04	0,03	1,16	2,09	5,60	31,84	12,23	10,90	10,41	4,46	2,95	5,13	6,23	6,95
RM	0,01	0,06	0,04	0,40	1,69	3,18	20,24	6,53	7,96	9,37	3,21	2,05	7,14	29,18	8,94
FP	0,00	0,00	0,09	0,16	0,90	3,36	10,92	5,50	2,80	7,93	0,96	0,71	5,90	48,02	12,74

TABELA 3 – PORCENTAGEM DE PIXEL DOS PADRÕES ENCONTRADOS PELA REDE EM RELAÇÃO AOS PIXELS DAS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV MAP-GAMMA

Classes	6	3	8	2	11	4	5	10	7	1	0	9
SE	59,76	37,90	1,41	0,09	0,05	0,63	0,05	0,04	0,07	0,00	0,00	0,00
PC	50,80	20,52	19,24	1,20	1,35	4,38	0,77	0,82	0,84	0,00	0,07	0,01
RN	0,84	0,43	64,23	2,49	6,77	1,34	19,47	0,35	4,05	0,03	0,00	0,00
RI	0,29	0,27	57,82	0,74	20,87	5,11	11,06	1,51	2,32	0,01	0,00	0,00
RA	0,00	0,00	5,87	0,94	15,49	0,32	29,86	4,01	43,29	0,00	0,09	0,14
RMA	0,00	0,00	3,18	1,19	8,63	0,53	13,16	3,43	60,59	0,06	4,71	4,50
FP	0,00	0,01	2,59	0,41	3,85	0,64	9,32	0,73	46,73	0,01	21,51	14,20

TABELA 4 – PORCENTAGEM DE PIXEL DOS PADRÕES EM RELAÇÃO ÀS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV ORIGINAL APÓS COMBINAR OS PADRÕES.

Classes	SE	PC	RN	RI	RA	RMA	FP
SE	88,55	3,47	0,59	4,68	1,87	0,15	0,69
PC	67,49	5,36	1,89	17,72	4,32	0,63	2,60
RN	10,25	1,81	15,22	46,94	17,14	5,06	3,58
RI	10,92	2,43	12,13	48,30	17,82	5,28	3,12
RA	1,70	0,97	12,51	19,43	32,87	17,34	15,19
RMA	1,73	0,62	7,48	12,47	27,69	18,47	31,55

FP	1,16	0,56	5,97	9,16	21,95	13,63	47,56
----	------	------	------	------	-------	-------	-------

TABELA 5 – PORCENTAGEM DE PIXEL DOS PADRÕES EM RELAÇÃO ÀS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV FROST E MEDIANA APÓS COMBINAR CLASSES.

Classes	SE	PC	RN	RI	RA	RMA	FP
SE	92,97	3,48	1,31	1,25	0,74	0,18	0,07
PC	65,91	8,84	5,80	12,08	5,47	1,27	0,63
RN	0,73	3,65	13,76	46,64	29,00	4,51	1,70
RI	0,36	2,31	11,84	48,68	30,81	5,25	0,75
RA	0,00	0,06	3,25	5,60	65,37	12,54	13,18
RMA	0,01	0,10	2,09	3,18	44,10	12,40	38,12
FP	0,00	0,09	1,06	3,36	27,15	7,57	60,76

TABELA 6 – PORCENTAGEM DE PIXEL DOS PADRÕES EM RELAÇÃO ÀS AMOSTRAS DAS CLASSES DE VERDADE DE CAMPO PARA AS IMAGENS HH E HV E VV MAP-GAMMA APÓS COMBINAR CLASSES.

Classes	SE	PC	RN	RI	RA	RMA	FP
SE	59,76	37,90	1,50	0,67	0,09	0,07	0,00
PC	50,80	20,52	20,44	5,73	1,58	0,84	0,08
RN	0,84	0,43	66,72	8,11	19,82	4,09	0,00
RI	0,29	0,27	58,55	25,98	12,58	2,33	0,00
RA	0,00	0,00	6,81	15,80	33,87	43,29	0,23
RMA	0,00	0,00	4,37	9,16	16,59	60,66	9,21
FP	0,00	0,01	2,99	4,50	10,05	46,74	35,71

A exatidão individual por classe mostrou que as classes SE, RI, RA e FP tiveram uma exatidão maior na classificação a partir das imagens filtradas com a seqüência dos filtros Frost e Mediana; e as classes PC, RN e RMA tiveram uma exatidão maior na classificação a partir das imagens filtradas com o filtro Map-gamma.

A partir destes resultados também foi possível calcular a exatidão global que é dada segundo Congalton e Green (1998) de acordo com a seguinte fórmula:

$$E_{global} = \frac{\sum_{i=1}^k n_{ii}}{n}$$

Onde: n_{ii} representa o nº de “pixels” classificados para cada classe (dispostos na diagonal principal da matriz de confusão), e n representa o número de classes.

De acordo com esta formulação; as imagens originais obtiveram 34,04% de exatidão; as imagens filtradas com Frost e Mediana obtiveram 43,70% de exatidão, e as imagens filtradas com Map-gamma obtiveram 46,94% de exatidão. A Figura 1 ilustra o resultado final das imagens classificadas com o número de padrões igual ao número de classes da verdade de campo, apresentando as imagens classificadas sem filtragem, com filtragem da seqüência Frost e Mediana e com o filtro Map-gamma.

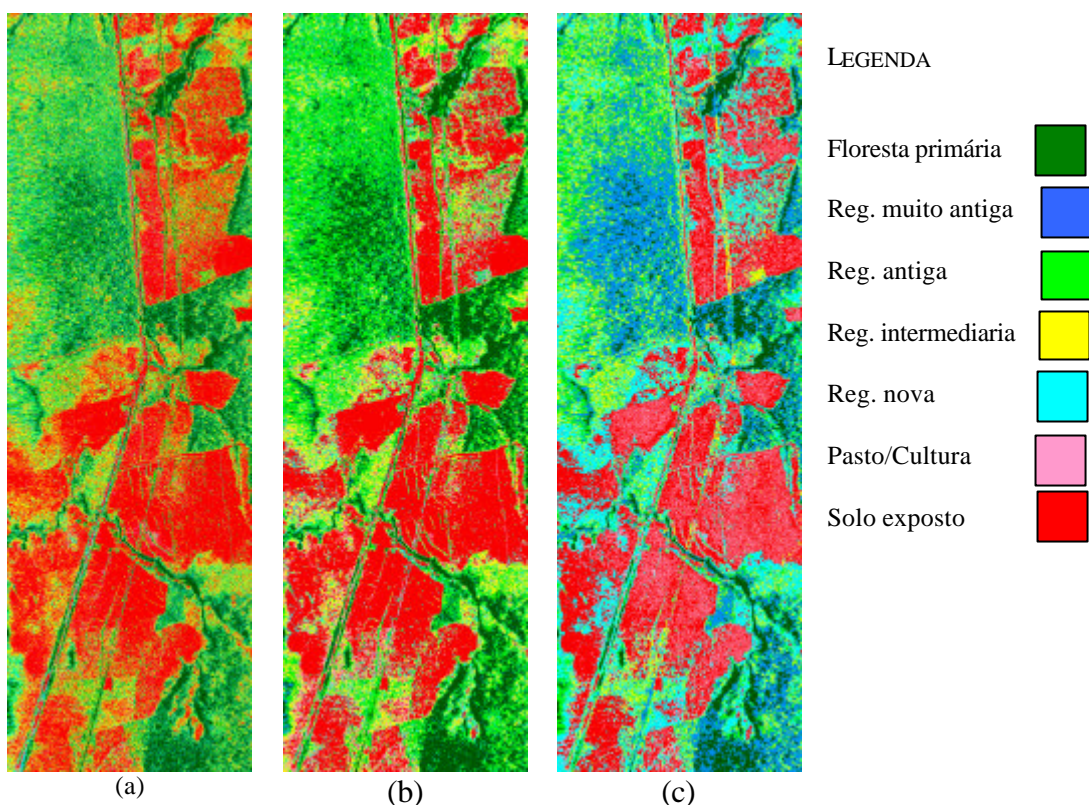


Figura 1 – Imagens classificadas: (a) sem filtragem, (b) filtradas c/ Frost e Mediana, (c) filtradas com Map-gamma.

8. Conclusões

A partir destes resultados podemos concluir que:

- 1º. O processo de filtragem melhorou o processo de classificação;
- 2º. O filtro Map-gamma apresentou o melhor resultado na redução do ruído “speckle” em relação à seqüência dos filtros Frost e Mediana;
- 3º. A exatidão global foi maior para as imagens filtradas com Map-gamma (5x5);
- 4º. Embora a exatidão global tenha mostrado que as imagens filtradas com o filtro Map-gamma tenha tido um desempenho maior, observamos que as classes mais representativas para estas imagens foram; PC, RN e RMA, que obtiveram uma alta porcentagem de confusão em relação às classes SE, RI, RA e FP que foram mais representativas nas imagens filtradas com os filtros Frost e Mediana.
- 5º. A exatidão da classificação por classe mostrou que as classes SE, RI, RA e FP foram às classes mais representativas, ou seja, as imagens de radar na banda P, aqui analisadas, foram mais sensíveis para discriminar e mapear estas classes.
- 6º. A exatidão individual da classificação de cada classe mostrou que as mesmas tiveram uma exatidão melhor de acordo com o tipo de filtro utilizado, conforme indicado na análise da SNR, o que demonstra que os filtros atuaram de forma diferenciada em relação aos alvos;
- 7º. A partir desta observação seria interessante fazer uma combinação entre estas classes que obtiveram um alto grau de confusão entre si e a partir desta nova combinação verificar o quanto à exatidão aumentou e para quais imagens esta

foi mais representativa, embora estivemos reduzindo o nível de abstração das imagens classificadas;

- 8º. A qualidade das amostras de verdade terrestre pode estar influenciando muito no resultado da exatidão global, seria necessário adotar critérios muitos rígidos na aquisição destas amostras, principalmente em relação ao tamanho e localização geográfica;
- 9º. Para estes dados de radar com comprimentos de onda muito grande (banda P), aqui analisados, verificou-se que os mesmos conseguem separar tipos de cobertura da terra até um nível de detalhamento não muito grande;
- 10º. A rede foi capaz de discriminar os tipos de cobertura existentes, sem introduzir qualquer tipo de informação a priori, embora com um certo grau de confusão, que é uma das principais características de um classificador pixel a pixel;
- 11º. Entretanto, a metodologia utilizada propiciou a obtenção de mapas de padrões, existentes utilizando imagens de radar polarimétrico, de forma rápida, permitindo que se tenha um estudo quase em tempo real da situação de áreas, colaborando como uma ferramenta na atualização de mapas temáticos e na fiscalização das atividades de ocupação e exploração por parte dos órgãos responsáveis.

9. Referências Bibliográficas

- Congalton, R. G.; Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Lewis Publishers, New York, 1998. 133 p.
- Gonçalves, M. L.; Andrade Neto, M. L.; Zullo Jr., J. Comparação de uma arquitetura neural com o algoritmo de máxima verossimilhança na classificação de uma cena LANDSAT/TM. In: Simpósio Brasileiro de Sensoriamento Remoto, 9., 11-18 set., 1998. **Anais**. Santos, São Paulo, INPE, [CD-ROM]. CN.
- Leckie, D. G.; Ranson, K. J. **Forestry Applications Using Imaging Radar**. In: Principles and Applications of Imaging Radar. 3.ed. John Wiley & Sons, Inc: New York, 1998. v. 2, Cap. 9, p. 435-509.
- Nepomuceno, A. M. **Reconhecimento de fitofisionomias do cerrado dentro do Parque Nacional de Brasília através de classificação de imagens de radar utilizando técnicas de filtragem no domínio do tempo**. Brasília. 44 p. Trabalho de conclusão de curso (Graduação em Engenharia Florestal) – Universidade de Brasília, 2000.
- Ribeiro, S. R. A.; Centeno, J. S. Classificação do uso de solo utilizando redes neurais e o algoritmo MaxVer. In: Simpósio Brasileiro de Sensoriamento Remoto, 10. **Anais**. Foz do Iguaçu, 21-26 abril 2001, INPE, p. 1341-1348, Sessão Pôster.
- Santa Rosa, A. N. C.; Meneses, P.R. Performance of MAP filters to reduce speckle in RADARSAT imagens. In: Simposio Final Globesar, 2., Bueno Aires. 1999. **Anais**. Bueno Aires, 1999, v. 1, n. 1, p. 876-880.
- Schowengerdt, R. A. **Remote Sensing: models and methods for image processing**. United States of America: Academic Press, 1997. 517 p.
- Silva, N. C. **Utilização de operadores genéticos para otimizar, classificadores neurais não-supervisionados de imagens**. Brasília. Tese (Doutorado em Ciência da Computação) – Universidade de Brasília, Instituto de Geociências, 2002. (no prelo).
- Silva, N. C.; Santa Rosa, A. N. C. Estimative of SOM Learning Parameters Using Genetic Algorithms In: 6th World Multiconference on Systemics, Cybernetics and Informatics, Orlando, 2002. **Anais**. Orlando, FL, USA, 2002, v. 1, n. 1, p.122-126.