

Classificação de imagens do Radar de abertura sintética do SIPAM com síntese genética de rede neural artificial.

Edinelson Ferreira de Sena^{1,2}
Antônio Nuno Castro Santa Rosa²

¹ Comando-Geral de Operações Aéreas – COMGAR
SHIS QI-05 – Área especial 12 CEP 71615-600 – Brasília-DF, Brasil
senaf@unb.br

² Universidade de Brasília - UnB
Campus Universitário Darcy Ribeiro CEP 70910-900 Brasília – DF, Brasil
nunos@gmail.com

Abstract. This paper deals with the use of national resources for the production of knowledge about the administrative region of Planaltina DF. The goal was the evaluation the potential use of Artificial Neural Network classifiers for the designation of ground targets from image of the R-99 airborne SAR Brazil, aiming to use a classifier for unsupervised pattern recognition with fuzzy logic. The tests were conducted with a sample of three distinct groups. After analyzing the results, we reached the conclusion that the implementation of work methodology adds value to existing resources in the Brazilian Air Force and national development projects of the Amazon Protection System (SIPAM), becoming one of the factors for quality and excellence of service to the nation.

Palavras-chave: SAR, Artificial Neural Network, SIPAM.

1. Introdução:

Os Estados necessitam de informações ágeis e confiáveis para a tomada de decisão. Em regiões menos habitadas do Brasil, não há dados disponíveis para análises, planejamento e execução de atividades civis e militares. A deficiência se torna maior se a decisão envolver a necessidade de conhecer dados da Amazônia.

Em virtude dessa deficiência, o Governo Brasileiro lançou o Programa do Sistema de Proteção da Amazônia (SIPAM) e, em 2002, a Aeronáutica adquiriu e passou a operar as aeronaves de sensoriamento remoto, R-99, equipadas com sensores óticos, hiperspectrais e com antenas do Radar de Abertura Sintética ou acrônimo inglês *Syntetic Aperture Radar* (SAR). Essas aeronaves são particularmente utilizadas para estudos em áreas extensas, em virtude de realizarem voos com pequena variação de ângulo de incidência e da aquisição de dados de agricultura, oceanografia, geologia e levantamento cartográfico, em territórios hostis (RENCZ, 1999). Isso demonstra a conhecida bivalência da Força Aérea Brasileira que, além de cumprir os requisitos constitucionais de defender a Nação, é precursora na busca da autonomia na obtenção de dados de sensoriamento remoto.

Conforme Nepomuceno (2003) “várias técnicas para automação do projeto de redes neurais vêm sendo desenvolvidas, visando resolver o problema de otimização de arquitetura neural”. Uma delas envolve a utilização de algoritmos genéticos, cujo propósito é a busca baseada no mecanismo de seleção natural genética (Nepomuceno, 2003b apud BRAGA et al., 1998).

O presente trabalho teve como objetivo principal avaliar o potencial da Síntese Genética de Rede Neural Artificial (SGRNA) para classificar os dados da Banda L (HH, HV, VH) nas configurações disponíveis e de forma não-supervisionada.

2. Materiais e Métodos

2.1 – Localização e características da área de estudo

A área de estudo está situada na Região Administrativa de Planaltina, dentro dos limites do Distrito Federal (DF), a Nordeste de Brasília e a 38 Km do centro da capital, nas coordenadas geográficas 15° 30' 00" S / 047° 45' 00" W e 15° 50' 00" S / 047° 20' 00" W.

Ela está situada na Bacia do rio Maranhão, no qual incluem os córregos do Palmito, Sítio Novo, Maria Velha, Taquara, Cachoeirinha; além do rio Pípiripau e dos ribeirões Palmeiras e São Gonçalo.

A bacia do rio Maranhão é extremamente importante para os recursos hídricos nacional e distrital, uma vez que é afluente de diversas bacias nacionais, entre elas as Bacias dos Rios Tocantins e Araguaia, possuindo, entre as bacias do Distrito Federal, a segunda maior disponibilidade hídrica (ZOTTICH, 2007).

Além disso, encontram-se a Estação Ecológica de Águas Emendadas e os parques de Sucupira, Estância e Retirinho. No contexto geral, as fitofisionomias encontradas são bastante preservadas e pouco degradadas, sendo as mais representativas do DF, das quais se destacam: Mata de Galeria, Cerrado rupestre, Cerrado *sensu stricto* e Campo Cerrado.

Observa-se que, nas áreas externa aos parques, em função da ocupação, estão as de cultivo e áreas de ocupação urbana.

A figura 1 representa os limites da área de estudo, bem como o extrato das porções imageadas pelo R-99, onde se tem essencialmente:

- a) Área "A": preservação. Estação Ecológica **Águas Emendadas**;
- b) Área "B": área urbana; e
- c) Área "C": região de agricultura.

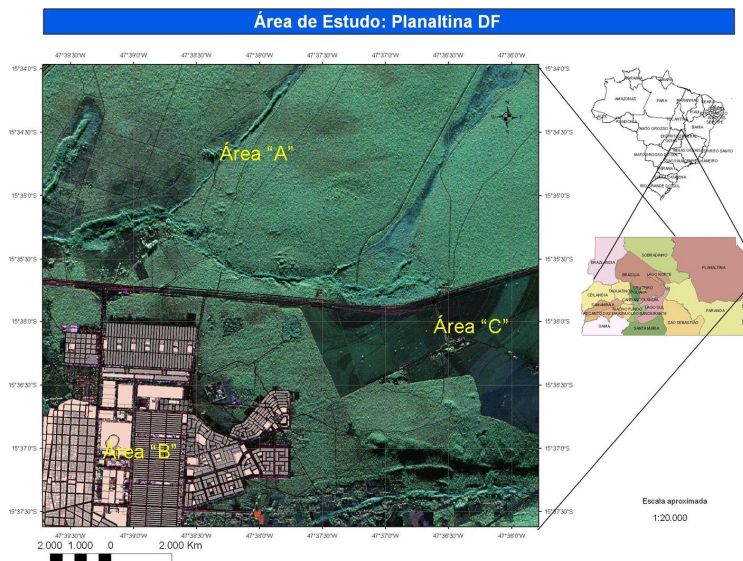


Figura 1 - Localização da área de estudo.

Para a composição da figura 1, utilizou-se uma imagem do da banda L do SAR, de 30 de abril de 2010, na qual se definiu para R=Lhv, G=Lhh e B=Lvv.

2.2 – Dados

Foram utilizadas imagens do sensor SAR, com data de aquisição de 30 de abril de 2010, da Banda L {Lvv, Lvh, Lhh, Lhv}, com comprimento de onda (λ) de 23 cm, compostas por um mosaico georreferenciado.

2.3 Procedimentos Metodológicos

A metodologia foi dividida em três fases importantes. Na primeira, os há o pré-processamento digital das imagens, no qual foram realizados os recortes, correção do padrão

de antena, redução do ruído Speckle e outros. Todos esses passos foram feitos no ENVI 4.5. Convém ressaltar que para redução do ruído Speckle, utilizou-se o filtro de Frost e o MAPGamma, alterado por Menezes e Santa Rosa (1999), e outras técnicas de geoprocessamento e manipulação de imagens.

Na segunda etapa, trabalhou-se com o programa de classificação de Síntese Genética de Redes Neurais Artificiais (SGRNA), desenvolvido pelo Prf. Dr. Nilton Correia da Silva.

Finalmente, os dados foram compilados e analisados à luz das ferramentas estatísticas, tal como o índice de Kappa.

2.3.1 Classificador de Síntese Genética de Redes Neurais Artificiais

Segundo Mather (2004) “O melhor sistema de interpretação de imagens que possuímos é a combinação de nossos olhos com o nosso cérebro”. Baseado nessa idéia, pesquisadores e estudiosos desenvolveram um modelo de classificador que pudesse agir semelhante ao processo de classificação utilizado pelo cérebro humano, no qual a construção de informações é feita por meio de *links* de unidades de processamento. Essas unidades recebem informações de outros neurônios, transformando-as, aperfeiçoando-as e finalmente enviando-as a outros neurônios, aplicando somente a soma dos conhecimentos processados para projetar um resultado, conforme representado na Figura 2 (GONÇALVES, 1996).

O sistema do processamento de cada neurônio pode ser representado em três etapas (Queiroz et al., 2004), como segue:

- A entrada das informações é realizada por um conjunto de sinapses, conexões, onde um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
- um somador para os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- uma função de ativação para restringir a amplitude da saída do neurônio (função de limiar).

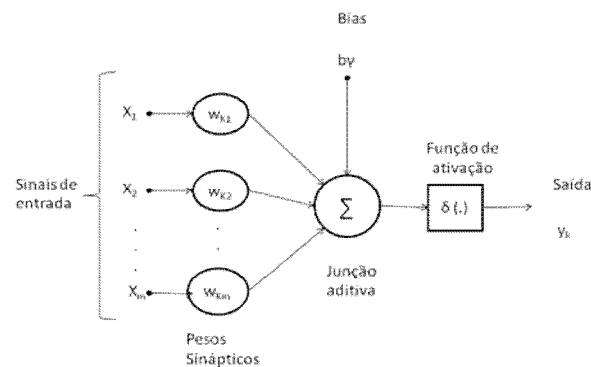


Figura 2 - Modelo de um neurônio de uma rede neural

Fonte: Queiroz et al., 2004

O procedimento de soma pode ser expresso por:

$$S = \sum_{i=1}^n w_i x_i \quad 2.1$$

Onde S representa a soma de “n” pesos de entrada, w_i é o peso associado com a entrada e x_i é o valor de entrada.

O modelo neuronal inclui também um “bias” cuja função é aumentar ou diminuir a entrada da função de ativação (dependendo se é positivo ou negativo). Cada neurônio recebe nas suas entradas valores das saídas dos neurônios conectados a ele. Esses sinais de entrada são multiplicados pelos respectivos pesos sinápticos das conexões e somados, gerando um

valor de ativação. O valor de saída do neurônio é resultado da comparação entre o seu valor de ativação e um determinado valor de limiar definido previamente (QUEIROZ et al., 2004).

Os mesmos autores descrevem a estrutura básica de uma rede neural, associando-a a pesos na entrada das sinapses. Como é mostrado na figura 3:




Figura 3 - Esquema de uma Rede Neural

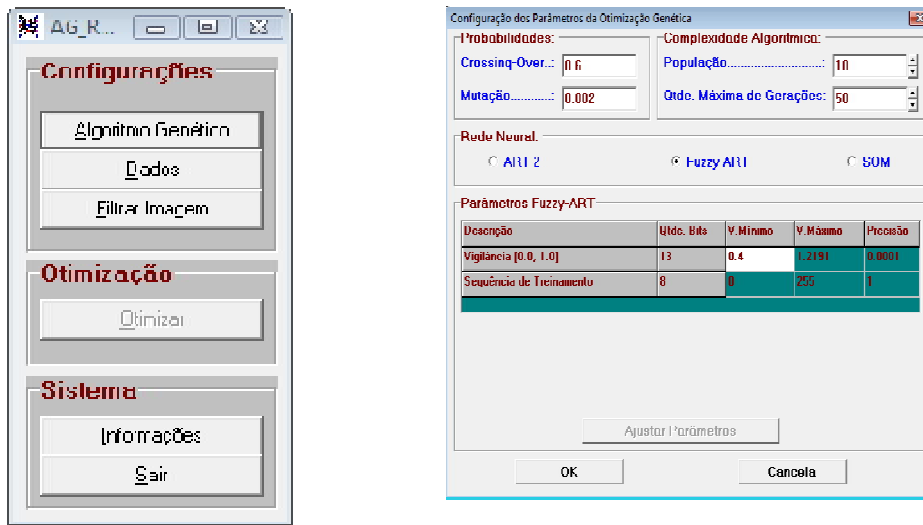
Fonte: Queiroz et al., 2004

O trabalho primordial realizado pelas redes neurais é a associação de padrões, pois a partir do momento em que uma rede é excitada por um estímulo inicial, é gerado um padrão final correspondente, tal qual o cérebro humano, demonstrando a capacidade de aprender através de exemplos (GONÇALVES, 1996).

Segundo Mather (2004), uma simples rede neural artificial tem um componente que a distingue de outros aplicativos, é a capacidade de aprender. Logicamente, alguns treinos são necessários para os neurônios se adaptem ao processo.

O agrupamento desses conceitos foi compilado para ser usado no classificador de SGRNA.

A parte 'a' da figura 4 apresenta a tela inicial do classificador. Nele o usuário pode trabalhar com as configurações do Algoritmo Genético, inserir dados e filtrar imagem, função recentemente implementada no classificador com o filtro MAPGamma, adaptado de Santa Rosa e Meneses (1999); Na parte 'b' se tem outra função importante: a otimização de dados. Nela o algoritmo Genético realiza o aprendizado e propõe as melhores soluções de classificação.



a) Tela inicial do classificador

b) Algoritmos disponíveis para classificação

Figura 4 - Apresentação inicial do classificador

Fonte: Adaptado de Silva, N. C., 2003.

Após as etapas iniciais, o sistema realiza a otimização dos dados e sugere uma resposta de classificação, conforme os parâmetros inseridos inicialmente.

A figura 5 representa o resultado desse processo. Neste caso, a classificação otimizada gerou 24 classes para a imagem SAR, na banda L, polarização HH. É importante notar o valor de vigilância: 0.933, responsável pelo nível de tolerância a discrepâncias entre as entradas do conjunto de treinamento das redes ART2 e Fuzzy-ART, e a sequência de treinamento: 9, define uma quantidade limitada de diferentes permutações do conjunto de treinamento (SILVA, 2003).

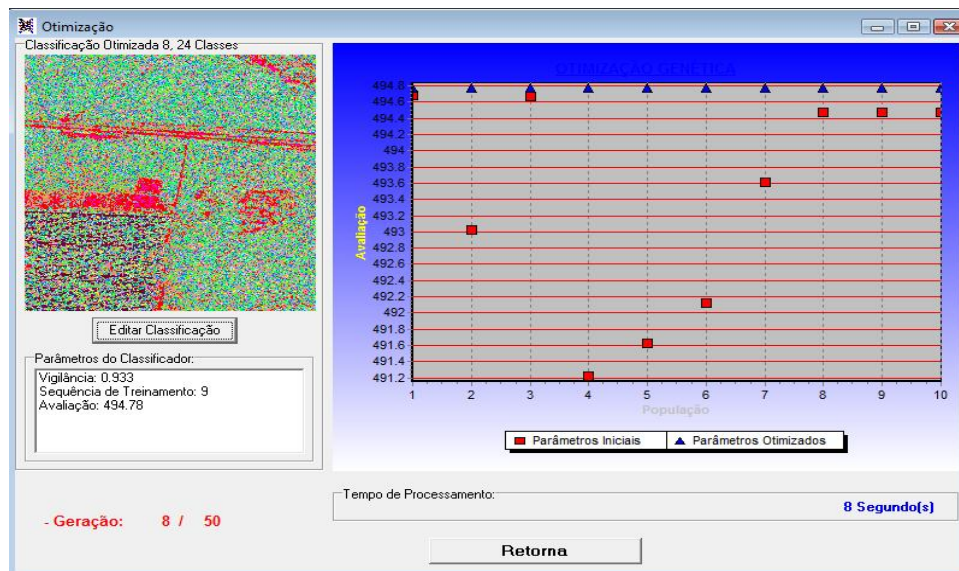


Figura 5 – resultado do processo de classificação.

Além disso, tem-se a possibilidade de editar a classificação gerada, conforme figura 6.

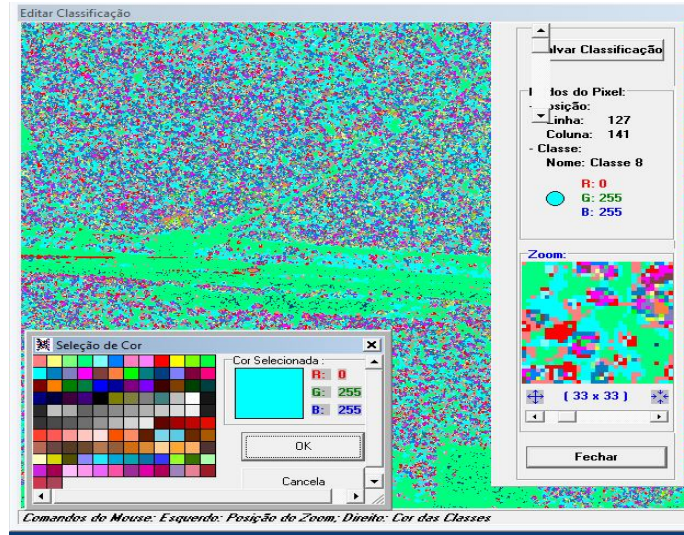


Figura 6 – Edição da classificação.

Com a análise de vários testes, nas bandas e polarizações disponíveis, constatam-se alguns resultados iniciais.

3. Resultados

Com o resultado das classificações, procedeu-se a avaliação das imagens temáticas geradas, com a obtenção das matrizes de confusão e o cálculo dos índices de Kappa.

As imagens geradas pelo classificador são mostradas a seguir. Os primeiros resultados indicam que a imagem que apresentou melhor discriminação das classes de uso e cobertura do solo foi a filtrada com o MAPGamma. A análise qualitativa destes resultados está em fase de processamento e os índices de exatidão de Kappa e global ainda são preliminares.

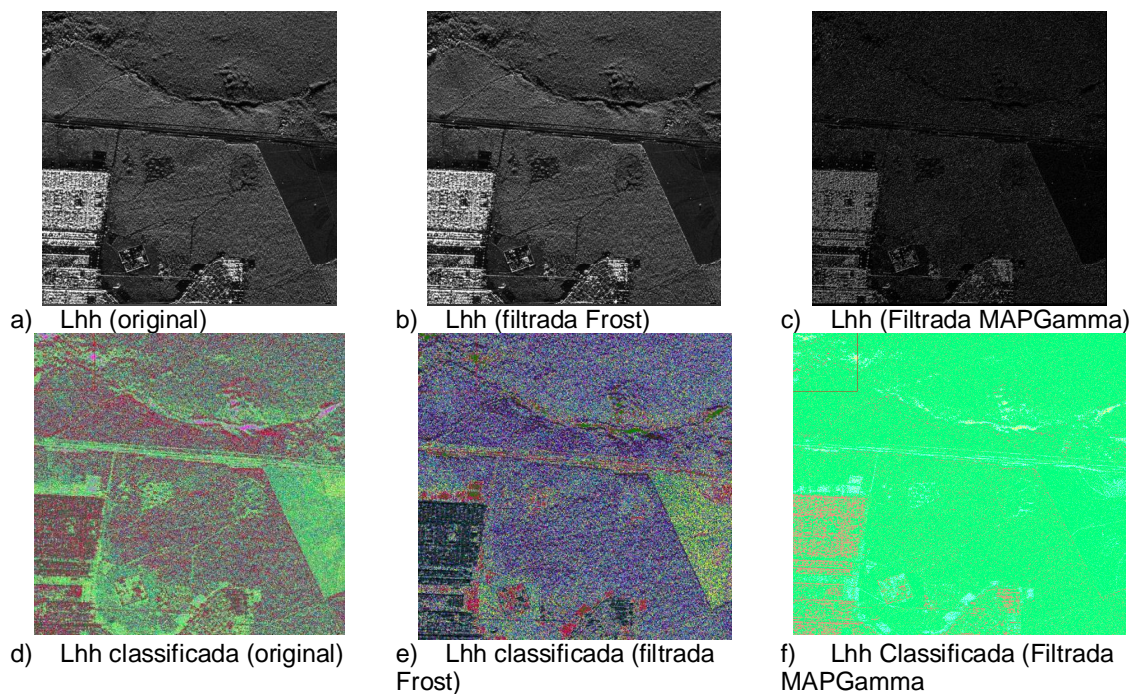


Figura 1 – Resultado da classificação gerada no SGRNA, na Banda L.

A fim de construir a matriz de confusão, foram selecionadas regiões de interesse na imagem original, corroboradas pela verdade de campo, nas quais se discriminam na tabela 1.

Tabela 1 – Classes selecionadas da área de estudo

Classe	Descrição	Polígonos	Pixels
Parque	Áreas de cerrado - Preservação ambiental	2	19.957
Agricultura	Áreas compostas por lavouras de soja.	3	16.475
Pastagem	Áreas cobertas de gramíneas, utilizada para o pastório	2	19.960
Urbana	Áreas urbanas	4	7.859
Estrada	Vias de comunicação	40	6.472

A tabela 2 indica a quantidade de padrões encontrados em cada classificação, ou seja, para cada resultado de classificação, o SGRNA possibilitou a discriminação de um determinado número de classes ou padrões.

Tabela 2 - Quantidade de padrões por classificação

Polarização	Sem filtrar	Frost (3x3)	MAPGamma (5x5)
hh	26	41	5
hv	10	25	10
vv	26	19	17
hh_hv_vv	31	35	53

A tabela 3 expressa o resultado dos parâmetros utilizados pela rede para realizar a classificação das imagens. Nela, percebe-se que o maior valor de vigilância indica maior quantidade de classes no classificador. Com isso, as classes foram mescladas

Tabela 3 - Parâmetros utilizados pela rede

Polarização	Parâmetro de Vigilância	sequência de treinamento	Avaliação	Geração
Sem filtrar				
hh	0.8882	361	496.66	3
hv	0.637	288	498.93	2
vv	0.9244	395	495.44	4
hh_hv_vv	0.5453	665	498.11	4
Frost (3x3)				
hh	0.9598	52	495.54	7
hv	0.8995	77	496.35	4
vv	0.8351	480	497.31	5
hh_hv_vv	0.6312	157	497.62	7
MAPGamma (5x5)				
hh	1.2362	113	495.81	1
hv	0.8345	97	494.99	8
vv	1.1269	319	495.59	2
hh_hv_vv	1.1408	853	498.85	1

4. Conclusões:

Apresentaram-se as principais características do Classificador de Síntese Genética de Redes neurais Artificiais que o definem como classificador não-supervisionado para imagens do sensor SAR, de acordo com as particularidades dessas imagens.

A região de Planaltina é caracterizada por extensa área de preservação ambiental e plantio de soja, possuindo uma cobertura da terra bastante heterogênea. Isso gerou uma miscelânea nos valores dos pixels classificados, o que dificultou a classificação.

A imagem que resultou com o melhor desempenho foi a classificada, após a filtragem com o MAPGamma.

Agradecimentos:

Comando-Geral de Operações Aéreas (COMGAR);
2º/6º Grupo de Aviação
Prof. Dr. Nilton Correia da Silva

Referências Bibliográficas:

- FONSECA, F. O. 2008. **Águas emendadas**. Secretaria de Desenvolvimento Urbano e Meio Ambiente. Brasília-DF.
- GONÇALVES, N. V. 1996 **Classificação automática de informações geomorfológicas utilizando redes neurais**. Dissertação de mestrado. Brasília. UnB. 103p.
- KINGSLEY, S. P. & QUEGAN, S (1992). **Understanding radar system. England. p.1-23.**
- KRAMER J. C. M., LACRUZ M. S. P., KEIL M., SANTOS J. R., ARAÚJO L. S. 2001. Razão entre bandas do SIR-C/X SAR para estimativa de biomassa em áreas de contato floresta e cerrado. In: X SBSR. Foz do Iguaçu. p. 1613- 1520.
- MATHER, PAUL M. 2004. **Computer processing of Remotely - Sensed Images: an introduction**. 3º ed. England, 319 pp
- MORAES NOVO, E. M. L. 2008. **Sensoriamento Remoto: princípios e aplicações**. 3 ed. São Paulo: Blucher. , pp.: 205-292.
- NEPOMUCENO, A. M.; VALERIANO, D. M.; FREITAS, C. C.; SANTA ROSA, A. N. C.; SILVA, N. C.; SANTOS, J. R.; DUTRA, L. V. 2003a. **Classificação de dados de radar para mapeamento de cobertura da terra na região de Santarém, Pará**. In.: Anais XI SBSR, Belo Horizonte, 2249-2256 p.
- NEPOMUCENO, A. M. 2003b. **Uso de rede neural artificial não supervisionada na classificação de dados de radar na banda-p para mapeamento de cobertura da terra em floresta tropical**. Dissertação de mestrado. São José dos Campos. INPE. 197p.
- QUEIROZ, ROSSANA B., SEVERINO, PRISCILA A. DA R, RODRIGUES, ANTONIO G., GÓMEZ, ARTHUR T. **Redes Neurais: Um comparativo com Máxima Verossimilhança Gaussiana na Classificação de Imagens CBERS 1**. II Workshop de Tecnologia da Informação aplicada ao Meio Ambiente – CBComp 2004 Inteligência Artificial.
- RENCZ, N. ANDREW. 1999. **Remote sensing for the earth sciences: manual of remote sensing**. 3º ed, vol. 3, Geological Survey of Canadá, p. 613-646.
- SANT'ANNA S. J. S., FERNANDES D., LACAVA J. C. S. 2001. Análise comparativa do desempenho de filtros redutores de "speckle" em imagens sar. In: IX SBT, Simp. Tel. Fortaleza.
- SANTA ROSA A. N. C. & MENESES P. R. 1999. Performance of MAP filters to reduce speckle in RADARSAT images. In: GLOBESAR. Buenos Aires. Proceedings. CONAE, v. 1, p. 876-880.
- SILVA, N. C. (2003) **Classificação semi-automática de imagens de sensoriamento remoto por meio de síntese genética de redes neurais artificiais**. Brasília. Tese (Doutorado em Geologia) – Universidade de Brasília, Instituto de Geociências.
- SIPAM. **Governo acelera conclusão do projeto Cartografia da Amazônia**. Disponível em: http://www.sipam.gov.br/index2.php?option=com_content&do_pdf=1&id=452. Acesso em 25/11/2008.
- ULABY, FAWWAZ T. E ELACHI, CHARLES (1990). **Radar polarimetry for geoscience applications**. Published 1990 by Artech House in Norwood, MA
- ZOTTICH, D. G., PINHEIRO, J. M., FREITAS, M. S., MEDEIROS, V. A. F. (2007) Aspectos fisiográficos, bióticos e antrópicos da bacia hidrográfica do rio Maranhão. Disponível: http://artigos.netsaber.com.br/resumo_artigo_14531/artigo_sobre_aspectos_fisiograficos_bioticos_e_antropicos_da_bacia_hidrografica_do_rio_maranhao. Acesso em: 14/10/2010.