



**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS**

**CLASSIFICAÇÃO DE IMAGENS DO RADAR DE ABERTURA
SINTÉTICA DO SIPAM COM SÍNTESE GENÉTICA DE
REDES NEURAIAS ARTIFICIAIS.**

EDINELSON FERREIRA DE SENA

Dissertação de Mestrado Nº 12

Brasília-DF
Março 2011



**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS**

CLASSIFICAÇÃO DE IMAGENS DO RADAR DE ABERTURA SINTÉTICA DO SIPAM COM SÍNTESE GENÉTICA DE REDES NEURAIS ARTIFICIAIS.

Edinelson Ferreira de Sena

Orientador: Prof. Dr. Antonio Nuno de Castro Santa Rosa

Monografia apresentada à Banca Examinadora do Instituto de Geociências, como exigência final para obtenção do Título de Mestre em Geociências Aplicadas.

Brasília-DF
Março 2011.

Sena, Edinelson Ferreira

Classificação de imagens do radar de abertura sintética do SIPAM com síntese genética de redes neurais artificiais. – Brasília 2011.

Dissertação de Mestrado – Universidade de Brasília, Instituto de Geociências.

Orientador: Pr. Dr. Antonio Nuno de Castro Santa Rosa.

1. Classificação. 2. Radar de abertura sintética. 3. SIPAM. 4. Síntese genética de redes neurais artificiais.

UNIVERSIDADE DE BRASÍLIA
Instituto de Geociência

**Classificação de imagens do Radar de Abertura Sintética
do SIPAM com Síntese Genética de Redes Neurais
Artificiais.**

Edinelson Ferreira de Sena

BANCA EXAMINADORA

Prof. Dr. Antonio Nuno de Castro Santa Rosa
Presidente

Prof. Dr. Nilton Correa da Silva
Membro

Prof. Dr. Edilson de Souza Bias
Membro

Brasília, 18 de fevereiro de 2011.

Dedicatória

À memória de meus pais Clóvis e Antônia, porque sempre me ensinaram que o estudo é a única forma honesta de vencer na vida; a minha esposa Yuri Melissa pelo carinho e apoio nas horas difíceis; e a Igreja que ora pelo nosso sucesso.

Agradecimentos

Agradeço a Deus pelas respostas de orações; ao meu orientador Prof. Dr. Antônio Nuno de Castro Santa Rosa; ao Prof. Dr. Nilton Correia da Silva, pelo apoio e generosidade ao disponibilizar o classificador de Síntese Genética de Redes Neurais Artificiais para análise e testes; a Alcina, por ter me ajudado na linguagem de programação IDL; ao Coronel Aviador, Raul dos Santos Barbeiro, cuja visão de futuro permitiu que a Força Aérea Brasileira capacitasse seus profissionais e técnicos para melhor desempenho das funções; ao meu colega de trabalho, Mansur, Engenheiro Eletrônico, que foi fundamental para o entendimento da complexidade das equações; ao companheiro Cristiano Silva pelo apoio no desenvolvimento de linguagem de programação C++. Aos meus amigos de turma: Edivaldo, Raul e Marina que como grupo coeso de estudo me incentivou na conclusão desta etapa.

Resumo

O presente trabalho trata da utilização dos recursos nacionais para produção de conhecimento sobre a região administrativa de Planaltina no DF. Esses recursos são imagens da banda L do radar de abertura sintética do SIPAM (SAR/R99) e um classificador não-supervisionado de síntese genética de redes neurais artificiais. O objetivo principal foi avaliar o potencial desse classificador para designação de alvos terrestres. A metodologia adotada envolveu técnicas de processamento digital de imagens, classificação e análise dos resultados. Os resultados indicaram que, dentro dos parâmetros estudados, o classificador atendeu às necessidades propostas e tem aplicação de forma auxiliar nas tarefas de interpretação de imagens, visando apoio à decisão em diversos ramos profissionais.

Abstract

This paper deals with the use of national resources for the production of knowledge about the administrative region of Planaltina DF. These features are images of the SIPAM's L-band Synthetic Aperture Radar (SAR/R99) and an unsupervised classifier for gene synthesis of artificial neural networks. The main objective was to evaluate the potential of these classifiers for the designation of ground targets. The adopted methodology included techniques of digital image processing, classification and analysis of results. With that, we reached the conclusion that the classification has real application in the task of image interpretation, decision support aimed at various professions.

Sumário

Resumo	vii
Lista de figuras	xii
Lista de Tabelas	xiv
Lista de Siglas e Abreviaturas	xv
1 INTRODUÇÃO	1
1.1 SITUAÇÃO PROBLEMA:	1
1.2 OBJETIVO DO TRABALHO	3
1.3 ORGANIZAÇÃO DO TRABALHO	3
2 ÁREA DE ESTUDO	4
2.1 SOLOS	5
2.2 RECURSOS HÍDRICOS SUPERFICIAIS	6
2.3 VEGETAÇÃO	6
2.4 CLIMA	6
3 REVISÃO BIBLIOGRÁFICA	7
3.1 CONSIDERAÇÕES INICIAIS SOBRE RADAR	7
3.1.1 Resolução de imagem radar	12
3.1.2 Equação radar	15
3.1.3 Interação da onda eletromagnética com a superfície terrestre	16
3.2 CARACTERÍSTICAS DO SENSOR MULTIPOLARIMÉTRICO AEROTRANSPORTADO BRASILEIRO	20
3.2.1 Aeronave de Sensoriamento Remoto	20
3.2.2 Antena SAR	22
3.2.3 Geometria do Imageamento	23
3.3 O RUÍDO SPECKLE	24

3.4	FILTRAGEM	26
3.4.1	Filtro de Lee	27
3.4.2	Filtro de Frost.....	27
3.4.3	Filtro MAP gamma	28
3.5	REDES NEURAIS ARTIFICIAIS	29
3.5.1	Tipos e Classificação de Redes Neurais Artificiais	31
3.5.2	Neurônio Biológico.....	32
3.5.3	Neurônio Artificial.....	33
3.5.4	Redes Neurais Artificiais Auto-organizáveis	35
3.5.5	Algoritmos Genéticos.....	40
3.6	CLASSIFICAÇÃO DE IMAGENS	43
3.7	ÍNDICE DE KAPPA	43
4	MATERIAIS E MÉTODO	48
4.1	MATERIAIS	48
4.1.1	Aquisição de dados.....	48
4.2	MÉTODO	49
4.2.1	Tipo de pesquisa.....	50
4.2.2	Pré-processamento digital das imagens.	51
4.2.3	Classificação dos dados da banda L	56
4.2.4	Dados de Campo	61
4.2.5	Avaliação da exatidão da classificação.....	63
4.2.6	Fluxograma da metodologia adotada no trabalho.....	64
5	RESULTADOS E DISCUSSÕES	65
5.1	IDENTIFICAÇÃO DO TIPO DE FILTRO	65
5.1.1	Análise qualitativa:	65

5.1.2	Análise quantitativa.....	66
5.2	ANÁLISE DO DESEMPENHO DA REDE DE KOHONEN	74
5.3	CLASSIFICAÇÃO DAS IMAGENS.....	78
6	CONSIDERAÇÕES FINAIS.....	83
7	REFERÊNCIAS BIBLIOGRÁFICAS	84
	APÊNDICE A – FILTRAGEM DE DADOS	86
	APÊNDICE B – CÓDIGO UTILIZADO NO MATCHAD PARA COMPOR O HISTOGRAMA DA FILTRAGEM DE DADOS	90
	APÊNDICE C – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O MSE	91
	APÊNDICE D – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O SNR.....	92
	APÊNDICE E – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O BETA	93
	APÊNDICE F – RESULTADOS DA REDE DE KOHONEN.....	94
	APÊNDICE G – MATRIZES DE CUNFUSÃO	98
	ANEXO A: ARTIGO ACEITO NO XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO	104

Lista de figuras

Figura 2-1 - Localização da área de estudo.	5
Figura 3-1 - Diagrama de bloco de um sistema radar elementar.	11
Figura 3-2 - Resolução espacial no Radar de Abertura Real	14
Figura 3-3 – Propagação da onda eletromagnética	18
Figura 3-4 – Exemplos de polarizações de uma onda REM.	19
Figura 3-5 - Localização dos sensores do R-99	20
Figura 3-6 – Antenas SAR do R-99.....	23
Figura 3-7 – Geometria do imageamento SAR	24
Figura 3-8 - Componentes do neurônio biológico.....	32
Figura 3-9 - Modelo não-linear de um neurônio.	33
Figura 3-10 - Esquema de uma Rede Neural.....	34
Figura 3-11 - Rede SOM típica.....	37
Figura 4-1 - Planejamento do voo do R-99SAR	49
Figura 4-2 - Comparação entre formatos	51
Figura 4-3 Transformação de dados em dB.....	52
Figura 4-4 Correlação entre as imagens antes e após a calibração.	53
Figura 4-5 Comparação do ND do pixel, após a calibração.....	54
Figura 4-6 - Tela inicial do classificador SGRNA.....	57
Figura 4-7 - Tela de escolha de parâmetros	58
Figura 4-8 - Inserção de dados no SGRNA.....	59
Figura 4-9 - Resultado do processo de classificação	60
Figura 4-10 – Tela de edição da classificação.	61
Figura 4-11 - Coleta da Região de Interesse (ROI).....	62

Figura 4-12 - fluxograma da metodologia.....	64
Figura 5-1 - Visualização da filtragem na imagem SAR. (A) Imagem original; (B) Filtro de Frost; (C) Filtro de Lee e (D) Filtro MAP gamma.....	66
Figura 5-2 - Filtragem das imagens SAR	68
Figura 5-3 - MSE e NSR	71
Figura 5-4 – Resultado da filtragem com Lee HV. Janelas (3x3), (5x5) e (7x7).....	72
Figura 5-5 -- Resultado da filtragem com Lee VH. Janelas (3x3), (5x5) e (7x7).....	72
Figura 5-6 - Resultado da filtragem com Lee HH. Janelas (3x3), (5x5) e (7x7).....	73
Figura 5-7 - Resultado da filtragem com Lee VV. Janelas (3x3), (5x5) e (7x7).....	73
Figura 5-8 - Resultado da filtragem com Lee HV, frost HV) e Map gamma HV. Janela (3x3).	74
Figura 5-9 - Classificação após filtragem com MAPGAD.	81
Figura 5-10 – Classificação após filtragem com Lee HV, com a janela 3x3.....	82

Lista de Tabelas

Tabela 3-1 - Principais missões orbitais SAR.....	8
Tabela 3-2 - Frequência de bandas dos radares.....	9
Tabela 3-3 - Resumo das resoluções de radar	14
Tabela - 3-4 Características do sensor SAR	22
Tabela 3-5 – Modelo de Matriz de confusão	44
Tabela 3-6 - KAPPA	46
Tabela 4-1 - Parâmetros iniciais do AG e da rede SOM	59
Tabela 4-2 - Amostras das classes de referência	62
Tabela 5-1 – Análise qualitativa das imagens, em relação ao tipo de filtro utilizado.	65
Tabela 5-2 – Resultados de MSE e SNR	69
Tabela 5-3 – MSE para filtragem com janelas estendidas	69
Tabela 5-4 – SNR para filtragem com janelas estendidas	70
Tabela 5-5 – Beta para filtragem com janelas estendidas.....	70
Tabela 5-6 - Resultado da rede SOM na imagem original.	75
Tabela 5-7 - Resultado da rede SOM com o filtro de Lee.	75
Tabela 5-8 - Resultado da rede SOM com o filtro de Frost.	76
Tabela 5-9 - Resultado da rede SOM com o filtro de MAP gamma.....	77
Tabela 5-10 - Resultado da classificação, após filtragem com Lee.....	78
Tabela 5-11 - Resultado da classificação, após filtragem com Front	79
Tabela 5-12 – Resultado da classificação, após filtragem com MAPGAD.	79
Tabela 5-13 – Concordância entre classificações, após filtragem com Lee e MAPGAD e na polarização HV.....	81
Tabela 5-14 – Concordância entre classificações, após filtragem com Lee e MAPGAD e na polarização HV.....	81

Lista de Siglas e Abreviaturas

AG's – Algoritmos Genéticos

ART - Adaptive Resonance Theory

FAB – Força Aérea Brasileira

RNA – Redes Neurais Artificiais

SAR – Synthetic Aperture Radar

SIPAM – Sistema de Proteção da Amazônia

SOM – Self-Organizing Map

1 INTRODUÇÃO

Faz-se uma breve descrição do tema abordado, insere o leitor no contexto do qual foi desenvolvido o trabalho. Inicia-se com uma breve descrição da situação problema, dos fatores que levaram a adoção da linha de pesquisa e das carências dos órgãos que detém os equipamentos sensores, mas não o conhecimento sobre o que podem gerar para o Brasil. Também são apresentados os objetivos desta dissertação.

1.1 SITUAÇÃO PROBLEMA:

Os Estados necessitam de informações ágeis e confiáveis para tomada de decisão, em uma ampla gama de atividades – política, econômica, tecnológica e militar (Política de Sensoriamento Remoto da Aeronáutica – DCA 510-1). Porém, em diversas regiões do Brasil, não há dados disponíveis para gerar informações e as análises, visando o planejamento, a execução e o controle de operações civis e militares ficam sensivelmente comprometidas. A deficiência se torna maior se a decisão envolver a necessidade de conhecer dados da Amazônia brasileira.

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, hiperespectrais e com antenas do Radar de Abertura Sintética (SAR). Essas aeronaves são particularmente utilizadas para estudos em áreas extensas, em virtude de realizarem voos com pequena variação de ângulo de incidência, ao longo da faixa imageada. Essa característica proporciona aquisição de dados de agricultura, geologia e levantamento cartográfico, com confiabilidade nos dados (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.

Aproveitando os sensores a bordo do R-99 e a capacitação técnico-operacional dos recursos humanos da FAB, o Governo Brasileiro iniciou o projeto denominado “Cartografia da Amazônica”, cujo viés de trabalho é o levantamento de

dados para preenchimento do vazio cartográfico existente na Amazônia, nas escalas 1:50.000 e 1:100.000 (Portal do SIPAM, 2008). O projeto envolve diversos ramos da sociedade e promove o intercâmbio de conhecimento técnico-científico entre o Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), a Aeronáutica, as demais Forças Armadas e os órgãos governamentais de ensino e pesquisa, ligados às atividades de sensoriamento remoto.

Aliado à estrutura de captação de dados do R-99, tem-se que o Brasil está entre os raros países, como os Estados Unidos, Alemanha, Canadá e França, que dominam a tecnologia de processamento e geração de imagens de alta resolução do sensor SAR, instalado nessas aeronaves.

Com o intuito de contribuir cientificamente no uso do sensor SAR das aeronaves de sensoriamento remoto da FAB, este estudo explora o potencial das redes neurais artificiais para classificar dados do Radar de abertura sintética, em um ambiente de teste típico do cerrado brasileiro.

No emprego da metodologia, optou-se por trabalhar com um classificador não-supervisionado, a fim de diminuir a interferência do usuário no processo de decisão sobre as classes selecionadas.

Finalmente, esta pesquisa almeja prosseguir com estudos e análises das imagens do SAR produzidas no território brasileiro; possui caráter inovador, pois utiliza dados polarimétricos da banda L, em todas as configurações das antenas do SAR; e, além disso, tem utilidade prática nas organizações da FAB, o que significa agilidade na aquisição de dados, metodologia de processamento, extração de informações e aplicação de resultados. Com isso, espera-se conhecer o que este sensor brasileiro pode proporcionar de dados, aperfeiçoar a produção de conhecimento sobre os classificadores de redes neurais artificiais e aumentar o domínio das técnicas de sensoriamento remoto, a fim garantir informações ágeis e confiáveis para assessorar a tomada de decisões.

1.2 OBJETIVO DO TRABALHO

Portanto, esta dissertação tem como objetivo geral **avaliar o potencial do classificador de Redes Neurais Artificiais para designação de alvos terrestres, a partir de imagens do R-99 SAR.**

Para atingir o objetivo geral, faz-se necessário percorrer os seguintes objetivos específicos:

- a) Avaliar filtros de eliminação de ruído speckle para análise de bordas; e
- b) Analisar o classificador de Síntese Genética de Redes Neurais Artificiais para alvos polarimétricos;

1.3 ORGANIZAÇÃO DO TRABALHO

A fim de proporcionar melhor entendimento, este trabalho encontra-se estruturado da seguinte forma:

No capítulo dois, faz-se uma análise das particularidades da área de estudo, tais como a localização, importância e fatores característicos da região.

No capítulo três, é apresentada a revisão bibliográfica com algumas considerações iniciais. Além disso, apresentam-se as características do sensor multipolarimétrico aerotransportado, polarização, ruído Speckle, filtragem, classificação de imagens e o uso de Redes Neurais Artificiais.

No capítulo quatro, são apresentados os materiais e método utilizado.

Finalmente, no capítulo cinco, são apresentados os resultados e as conclusões alcançadas, a partir de dados do SAR R-99, segundo as técnicas de geoprocessamento adotadas.

2 ÁREA DE ESTUDO

Apesar da mobilidade que a plataforma R-99 proporciona ao se deslocar em todo o território nacional, escolheu-se uma área teste próxima a Brasília onde houvesse alvos de natureza nativa do cerrado, área urbana e áreas agriculturáveis. Além disso, verificou-se que, para fins de validação de dados, era necessário optar por uma região que existisse razoável desnível de altitude, o que reduz os efeitos de rugosidade do terreno, constante dielétrica e geometria de imageamento sobre do alvo, pois, sabe-se que esses efeitos influenciam diretamente no retroespalhamento e na análise dos produtos decorrentes (ANDRADE E VEIGA, 2002).

Assim sendo, a área de estudo está situada na Região Administrativa de Planaltina, dentro dos limites do Distrito Federal, a Nordeste de Brasília e a 38 Km do centro da capital, limitada pelas coordenadas geográficas 15° 30' 00" S / 047° 45' 00" W e 15° 50' 00" S / 047° 20' 00" W, possuindo ampla e consolidada ocupação urbana com algumas propriedades que ainda mantêm o uso original do solo e uma área de parque de preservação (Secretaria de Estado de Planejamento, Coordenação e Parcerias do Distrito Federal – Anuário Estatístico do Distrito Federal 2006).

A figura 2-1 representa os limites da área de estudo, bem como o extrato das porções imageadas pelo R-99, onde se tem essencialmente:

- a) Área "A": área de cerrado (estação ecológica águas emendadas);
- b) Área "B": área urbana; e
- c) Área "C": área de agricultura.

Com isso, entende-se que as amostras coletadas nas imagens foram melhores aproveitadas para estudo da polarimetria desses alvos.

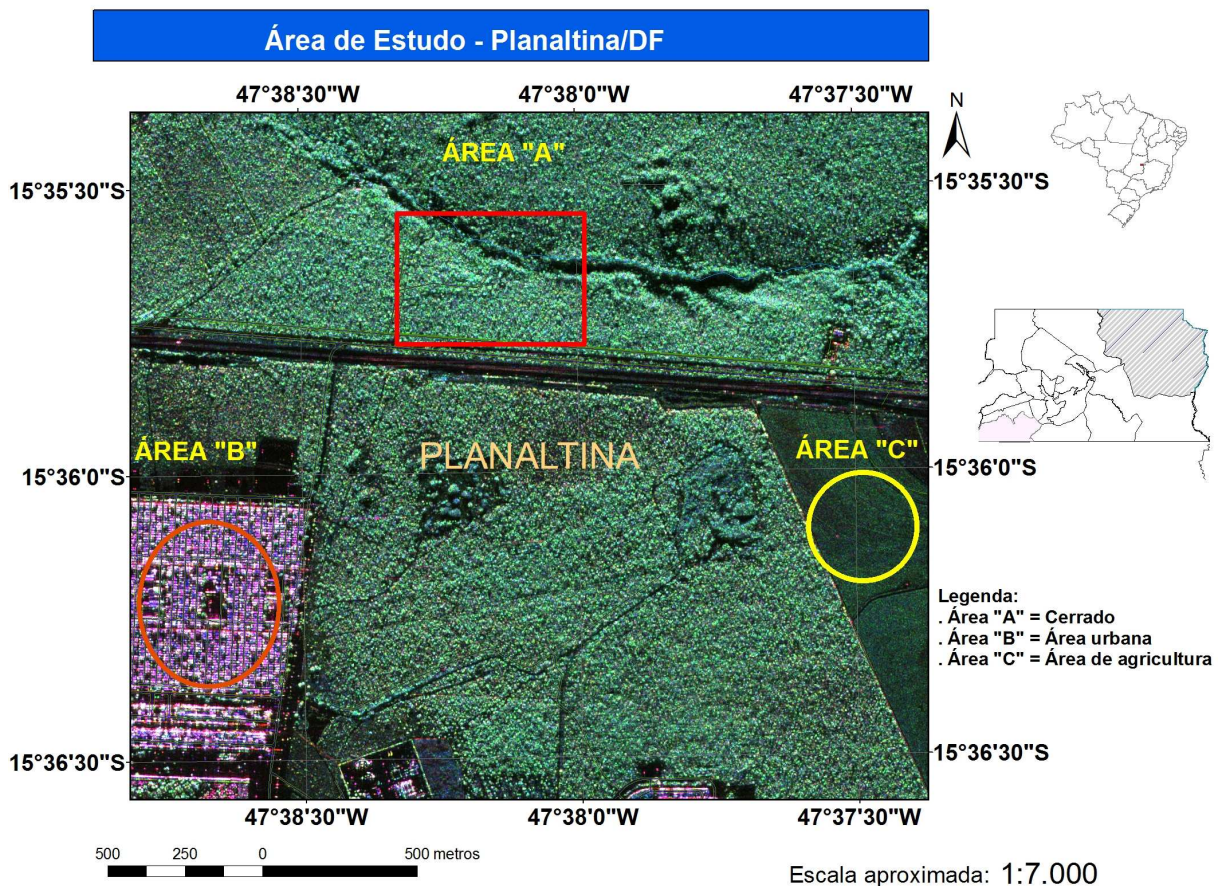


Figura 2-1 - Localização da área de estudo.

A composição da figura 2.1 foi feita com uma imagem da banda L do SAR, de 30 de abril de 2010, na qual se definiu para R=Lhv, G=Lhh e B=Lvv.

2.1 SOLOS

De forma geral, o Cambissolo predomina na área de estudo (57,15%). Este tipo de solo é caracterizado por ser pouco desenvolvido, com minerais facilmente intemperizados e associados a relevos mais movimentados (Reatto et. al., 1998). Também possui latossolos vermelho-escuro (11,26%) e o vermelho-amarelo (30,27%), localizados em áreas mais planas e mais altas, enquanto os solos hidromórficos (1,30%), geralmente inundáveis e extremamente sensíveis, localizam-se em áreas mais baixas da região.

2.2 RECURSOS HÍDRICOS SUPERFICIAIS

A área de estudo está situada na Bacia do Rio Maranhão, na qual incluem os córregos do Palmito, Sítio Novo, Maria Velha, Taquara e Cachoeirinha; além do Rio Píripau e dos ribeirões Palmeiras e São Gonçalo.

Essa bacia é extremamente importante para os recursos hídricos nacional e distrital, porque é afluente de outras bacias nacionais, dentre elas, citam-se as dos Rios Tocantins e Araguaia. Possui a segunda maior disponibilidade hídrica do Distrito Federal (ZOTTICH. 2007).

2.3 VEGETAÇÃO

A região Administrativa de Planaltina, apesar da ocupação humana, ainda possui vegetação nativa do cerrado. Nela se encontram a Estação Ecológica de Águas Emendadas e os parques de Sucupira, Estância e Retirinho. Na área de estudo, as fitofisionomias encontradas são bastante preservadas e pouco degradadas, sendo que se destacam a Mata de Galeria, o Cerrado rupestre, o Cerrado *sensu stricto* e o Campo Cerrado, como as fitofisionomias mais representativas da região.

2.4 CLIMA

Em parte, o clima da região acompanha o do Distrito Federal. É tropical de altitude, com um verão úmido e chuvoso e um inverno seco e relativamente frio. A temperatura média anual é cerca de 21°C, podendo chegar aos 29,7 °C de média das máximas em setembro, e aos 12,5 °C de média das mínimas nas madrugadas de inverno em julho. A umidade relativa do ar é de aproximadamente 70%, podendo chegar aos 20% ou menos durante o inverno. (fonte: INMET, 2010).

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentados os principais conceitos que envolvem o teor central do trabalho: o Radar de Abertura Sintética, a polarização e a classificação.

3.1 CONSIDERAÇÕES INICIAIS SOBRE RADAR

Os primeiros estudos envolvendo experimentos com frequências de microondas foram feitos em 1886, pelo físico alemão Heinrich Hertz. Neles, o pesquisador utilizou a teoria eletromagnética de Maxwell para demonstrar que vários objetos, metálicos e não metálicos, podiam refletir a radiação numa frequência de aproximadamente 200 MHz. Em 1903, quinze anos após os experimentos de Hertz, Christian Hülsmeier, também da Alemanha, demonstrou o uso de radar como anticollisão de navios. Posteriormente (1943), Pierre David utilizou o primeiro sistema de pulso de radar, operando em uma frequência de portadora de 60 MHz, capaz de localizar aviões. Paralelamente, um sistema de rastreamento e detecção de aeronaves foi desenvolvido com sucesso na Alemanha e Grã-Bretanha. Ao Sir. Watson-Watt são creditados os méritos pela construção do primeiro sistema radar operacional (1939). Este sistema foi usado durante a 2ª Grande Guerra para rastrear aeronaves na Europa ocidental. Naquela época, os radares se tornaram importantes ferramentas para previsão de ataques inimigos.

No início de 1950, engenheiros reconheceram que, ao invés de girar a antena de radar para fazer varredura da área de um alvo, poder-se-ia fixá-la à fuselagem de aeronaves. Isto permitiu criar uma abertura muito maior e aprimorar a resolução no sentido de varredura do voo. Em 1978, houve o desenvolvimento do primeiro SAR orbital pela SEASAT (EUA) e da tecnologia InSAR (SAR interferométrico). Entre 1981 e 1984, aconteceram as missões do ônibus espacial colômbia para coleta de dados SAR, nas bandas L, C e X. Na década de 90, vários satélites começaram a fornecer cobertura radar da superfície terrestre, dentre eles, o Radarsat, JERS e ERS.

A tabela 3.1 apresenta o resumo das principais missões orbitais SAR.

Tabela 3-1 - Principais missões orbitais SAR

SISTEMAS	Seasat	ALMAZ	ERS-1 e 2	JERS-1	LACROSSE	RADARSAT
País	EUA	Rússia	Europa	Japão	EUA	Canadá
Início	16/06/1978	31/03/1991	jul/91 e abr/95	11/02/1992	13/12/1988	1996
Vida útil	3 meses	1,5 ano	2-3 anos	2 anos	-	5 anos
Frequência	L (1,2 GHz)	S (3 GHz)	C (5,3 GHz)	L (1,2 GHz)	X (9,5 GHz)	C (5,3 GHz)
Polarização	HH	HH	VV	HH	HH	HH
Âng. Incid.	23°	30°- 60°	23°	39°	Variável	10°- 60 °
Comp. Onda	23 cm	10 cm	5,6 cm	23 cm	3 cm	5,6 cm
Resolução (y)	25 m	15 m	26 m	18 m	1 m	9-100 m
Resolução (x)	25 m	15 m	28 m	18 m	1 m	10-100 m
Altura de Vôo	800 km	300 km	785 km	568 km	275 km	800 km
Larg. de Faixa	100 km	20-45 km	100 km	75 km	Variável	Variável
Antena	10 m	15 m	10 m	12 m	8 x 2 m	15 m

Fonte: ¹Instituto de Estudos Avançados da FAB (2007).

Kingsley e Quegan (1992) citam que "radar é tudo o que usa ondas de rádio para detectar a presença de objetos e encontrar sua posição". A palavra radar é uma abreviatura de *RADio Detection And Ranging* e, em geral, sistemas radares usam ondas moduladas e antenas direcionais para transmitir a energia eletromagnética em um volume de espaço para buscar alvos. Os objetos (alvos) dentro de um volume de pesquisa refletirão parte dessa energia (retorno ou ecos) de volta ao radar. Estes ecos são processados pelo receptor da antena e as informações do alvo são extraídas, tais como: alcance, velocidade, posição angular e outras características de identificação.

Radares podem ser classificados como terrestres, aéreos, espaciais ou sistemas de radares em navios. Eles também podem ser classificados em numerosas categorias, baseados nas características específicas do radar, tais como, frequência da banda, tipo de antena, e comprimento de onda utilizado. Outra

¹ Extraída de aula no curso de Espectrometria por imageamento radar (2007)

classificação diz respeito com a missão ou funcionalidade do radar. Isto inclui: meteorológico, busca e aquisição, monitoramento, controle de fogo e radares de alerta. Também existem os radares multifuncionais que englobam mais de uma categoria.

A maioria das vezes, os radares são classificados pelo tipo de onda que usam ou pela frequência de operação. Considerando a forma de onda, os radares podem ser de onda contínua (acrônimo *Continuous Wave* – CW) ou pulsada (acrônimo *Pulsed Radars* – PR). Radares CW são aqueles que continuamente emitem a energia eletromagnética e usam antenas diferentes para transmissão e recepção. Nesta categoria, os radares podem ser classificados como: frequência de repetição de pulso (acrônimo *Pulse Repetition Frequency* – PRF), baixa PRF, média PRF e alta PRF.

A tabela 3.2 apresenta a lista das principais designações das frequências utilizadas pelos radares.

Tabela 3-2 - Frequência de bandas dos radares.

Designação	Frequência (GHz)	Comprimento de onda (cm)	SAR - SIPAM (λ cm)
HF	0,003 - 0,03	1000 - 10000	-
VHF	0,03 - 0,3	100 - 1000	-
UHF	0,3 - 1,0	10 - 100	-
Banda P	0,3 - 1,0	30 - 100	
Banda L	1,0 - 2,0	15 - 30	23,4
Banda S	2,0 - 4,0	7,5 - 15	-
Banda C	4,0 - 8,0	3,75 - 7,5	-
Banda X	8,0 - 12,5	2,4 - 3,75	3,12
Banda Ku	12,5 - 18,0	1,67 - 2,4	-
Banda K	18,0 - 26,5	1,1 - 1,67	-
Banda Ka	26,5 - 40,0	0,75 - 1,1	-

Fonte: Adaptada de Mahafza (2000)

As Altas frequências (HF) são utilizadas para a reflexão da onda eletromagnética na ionosfera e detectar alvos além do horizonte. Frequência muito alta (VHF) e frequência ultra alta (UHF) são comumente utilizadas para transmissão

de rádio FM e televisões, além de serem empregadas para sistema de navegação, comunicações aéreas e por radioamadores. Radares na banda L são utilizados para controle de tráfego aéreo e operações militares. Às vezes, é necessária a comunicação de navios com a equipe de Terra. Nestes casos, a banda S é empregada para operar com segurança. Para detecção de mudanças climáticas, usa-se a banda C. A banda X é utilizada por sistema radares onde o tamanho da antena constitui uma limitação física, isto inclui os radares aerotransportados. As bandas Ku, K e Ka sofrem atenuações pelas condições meteorológicas e atmosféricas, por isso, possuem poucas aplicações (MAHAFZA, 2000, pag 3; e OLIVER QUEGAN, 1998, pag, 1-7).

O princípio de funcionamento Radar baseia-se na medição do tempo de propagação que uma radiação eletromagnética emitida pelo próprio radar, leva para atingir um objeto e retornar. A posição do objeto é determinada quando se converte o tempo de propagação em distância radial e assume-se sua direção com a de apontamento da antena. Para observação terrestre, os comprimentos de ondas (λ) utilizados se situam entre 3 mm e 30 cm.

A figura 3-1 mostra um sistema radar básico. Neste exemplo, o radar transmite um pulso de curta duração; o pulso se propaga a partir da antena, expandindo-se pelo meio de propagação (espaço ou atmosfera); ao incidir sobre um objeto refletor (Terra, mar, navio, aeronaves), parte da energia é redirecionada para antena receptora; a energia retorna ao radar percorrendo o mesmo meio de propagação; e o sinal é amostrado, processado e armazenado.

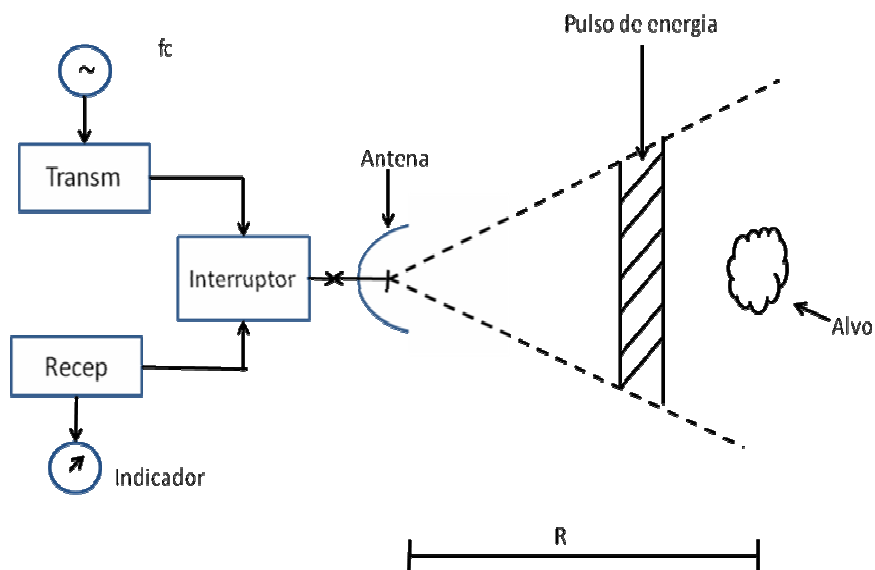


Figura 3-1 - Diagrama de bloco de um sistema radar elementar.

Fonte: Adaptado de Curlander e McDonough (1991)

A distância do alvo, R , pode ser calculada pela demora do tempo de propagação do sinal ao atingir o alvo e voltar à antena. Lembrando que a velocidade = espaço / tempo, tem-se.

$$R = ct/2 \text{ (m)}$$

(3-1)

Onde:

R = alcace (m),

c (velocidade da luz) = $3 \times 10^8 \text{ ms}^{-1}$ e

t = demora do tempo da propagação do sinal (s).

Os Radares de abertura real transmitem e recebem sinais de microondas com a antena de comprimento fixo. Eles são limitados na capacidade de produzir resoluções fina o suficiente para a maioria das aplicações de sensoriamento remoto, simplesmente porque se torna difícil transportar uma antena muito longa. A partir dessa dificuldade, surgiu o SAR, cujo intuito é de aumentar a resolução espacial, sem que seja necessário aumentar o tamanho físico da antena. Nele, o sistema

coerente registra a fase e a magnitude do sinal retroespalhado (eco) pela superfície imageada.

Há várias aplicações para as imagens de radar, das quais se destacam: o interesse militar, a verificação de tratados internacionais, a interferometria, a penetração no solo e no dossel (biomassa), vigilância ambiental, defesa civil, cartografia (planimetria e altimetria), batimetria e redes de transporte.

Curlander e McDonough (1991) e Kingsley e Quegan (1992) afirmam que, diferente dos sensores óticos, há algumas vantagens que demonstram o porquê do SAR ser considerado um instrumento único no sensoriamento remoto: visão sinótica, sem interferência de nuvens para mapeamento nas escalas de 1:25.000 a 1:400.00; imageamento de dia ou de noite e independente das condições atmosféricas; as imagens em comprimento de ondas longas fornecem dados sobre a rugosidade do terreno, propriedades dielétricas e umidades do solo; resolução geométrica independe da altitude do sensor; e as imagens podem ser produzidas em diferentes tipos de energia polarizada (HH, VV, HV e HV)

3.1.1 Resolução de imagem radar

Um elemento de resolução é definido como a menor distância que se podem distinguir dois objetos ou a distância entre os centros de dois ecos pontuais, de tal forma que estes ecos não se sobreponham (GOJ, 1993, p. 1-31).

Um radar de visada lateral, com abertura real, proporciona três tipos distintos de resolução: resolução de linha de visada ou radial p_{LV} (*slant range resolution*); resolução transversal e resolução em azimute.

Apesar das três resoluções apresentadas, as mais usuais são a resolução transversal (a normal do vetor velocidade da plataforma) e a resolução em azimute (paralela ao vetor velocidade da plataforma).

A Resolução transversal p_t (*cross-track* ou *ground range resolution*) é definida como:

$$\rho_r = \frac{ct}{2\text{sen}(\theta)} \quad (3-2)$$

Onde:

c = velocidade da luz

t = largura de pulso transmitido

θ = ângulo de passagem

A Resolução em azimute ρ_a (*along-track* ou *azimuth resolution*) é definida como:

$$\rho_a = R\beta_h \quad (3-3)$$

Pode ser aproximada para:

$$\rho_a = R \left(\frac{\lambda}{L} \right) \quad (3-4)$$

Baseado na largura nominal do feixe: $\beta_h = \lambda/L$, onde:

R = alcance inclinado ao alvo

β_h = largura de feixe da antena radar

λ = comprimento de onda

L = tamanho físico da antena.

A figura 3-2 representa visada lateral de um SAR aerotransportado e a geometria dos tipos de resolução.

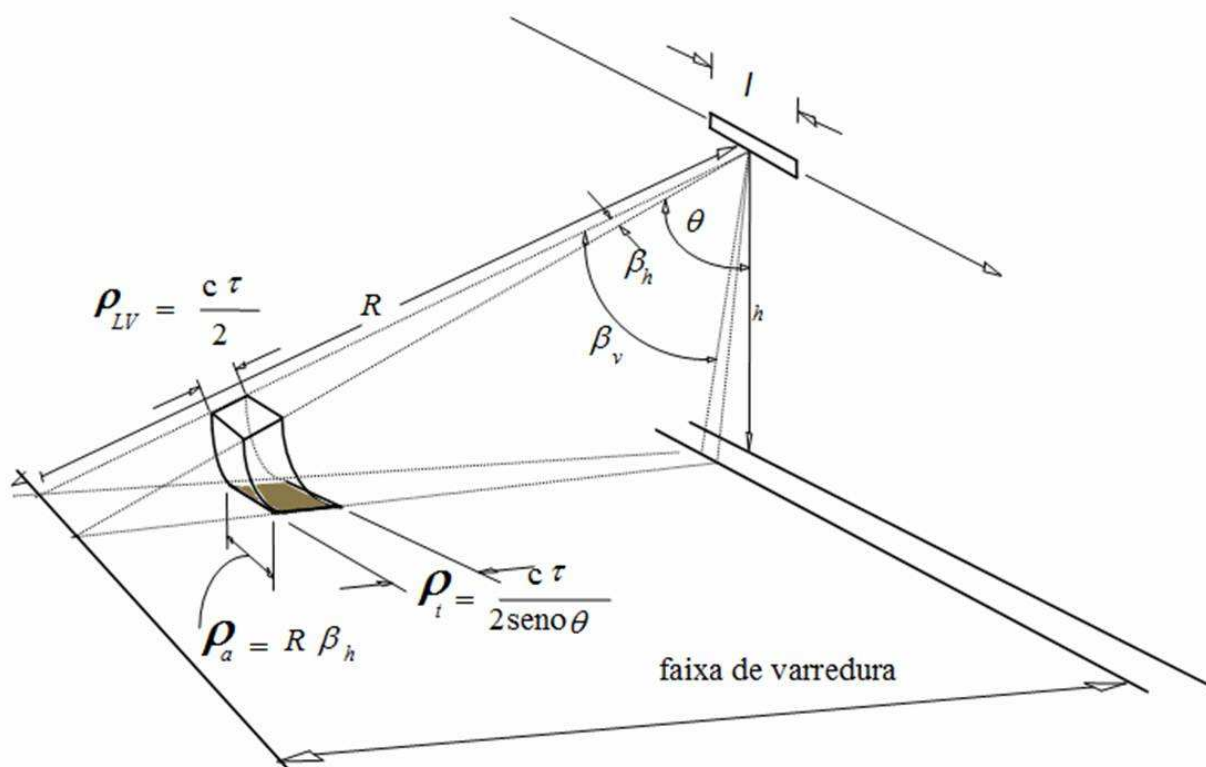


Figura 3-2 - Resolução espacial no Radar de Abertura Real

Fonte: ² Estágio Básico de Sensoriamento Remoto da FAB (2007).

A tabela 3-2 é um resumo das resoluções transversal e azimutal dos radares de abertura real e sintética.

Tabela 3-3 - Resumo das resoluções de radar

RESOLUÇÃO \ RADAR	REAL	SAR
Transversal	$\rho_r = \frac{ct}{2\text{sen}(\theta)}$	$r_r = \frac{c}{2B\text{sen}\theta}$
Azimutal	$\rho_a = R\beta_h$	$r_a = \frac{l}{2}$

Fonte: Adaptada de GOJ (1993)

² Extraída de aula no curso de Espectrometria por imageamento radar (2007)

3.1.2 Equação radar

Considere um radar com uma antena omnidirecional, aquela que irradia energia igualmente em todas as direções. Esses tipos de antenas têm um padrão de radiação esférica. Pode-se definir a densidade de potência máxima da antena, em qualquer ponto do espaço, como:

$$P_D = \frac{\text{potência de transmissão (watts)}}{\text{área da esfera (m}^2\text{)}} \quad (3-5)$$

A densidade de potência de alcance R distante do radar (assumindo uma perda de propagação média) é:

$$P_D = \frac{P_1}{4\pi R^2} \quad (3-6)$$

O sistema de radar utilizar antenas direcionais de modo a aumentar a densidade de potência em uma determinada direção. Antenas direcionais são normalmente caracterizadas pelo ganho (G) e pela abertura da antena (A_e), caracterizadas como:

$$A_e = \frac{G\lambda^2}{4\pi} \quad (3-7)$$

A densidade de potência R distante de uma antena direcional de ganho (G) é definida como:

$$P_D = \frac{P_1 G}{4\pi R^2} \quad (3-8)$$

Quando a energia radar atinge um alvo, a superfície do alvo irradia a energia eletromagnética em todas as direções. O montante da energia é proporcional ao tamanho, orientação, forma física e material do alvo, no qual são agrupados em um único parâmetro específico, chamado *Radar Cross Section* (RCS) e denotado por σ . Assim, a densidade de potência irradiada pelo alvo é dada por:

$$P_{Dr} = \frac{P_1 G \sigma}{4\pi R^2} \quad (3-9)$$

Então, a densidade de potência que chega a antena (radar), oriunda do alvo, é dada por:

$$P_{Dr} = \frac{P_1}{4\pi R^2} G\sigma \frac{1}{4\pi R^2} \quad (3-10)$$

Agora, levando-se em consideração a área de recepção da antena (A_r), temos:

$$P_{Dr} = \frac{P_1}{4\pi R^2} G\sigma \frac{1}{4\pi R^2} A_r \quad (3-11)$$

A relação entre o ganho e a área de recepção é dada por:

$$A_r = \frac{\lambda^2 GR}{4\pi} \quad (3-12)$$

Portanto, a equação radar para uma densidade de potência (P_D) fica:

$$P_{Dr} = \frac{P_1}{4\pi R^2} G\sigma \frac{1}{4\pi R^2} \frac{\lambda^2 GR}{4\pi} \quad (3-13)$$

3.1.3 Interação da onda eletromagnética com a superfície terrestre

Curlander & McDonough (1991) expressam que o retroespalhamento ou as características da onda refletida no terreno (amplitude, fase e polarização), dependem de três parâmetros da superfície terrestre: constante dielétrica (permissividade), rugosidade (rms altura) e declividade (geometria).

Se assumirmos que a onda se propaga em um meio homogêneo, isotrópico, então a equação de Maxwell pode ser expressa para um vetor campo elétrico complexo como:

$$E(z,t) = A \exp[j(k'z - \omega t + \Phi)] \quad (3-14)$$

Onde A é o vetor amplitude. A frequência angular ω é dada por:

$$\omega = 2\pi f_c = 2\pi c / \lambda \quad (3-15)$$

Onde f_c é a frequência e λ é o comprimento de onda. A onda se propaga na direção z , onde relaciona k' ao número de ondas k , dado por:

$$k' = \sqrt{\epsilon_r} k = 2\pi \sqrt{\epsilon_r} / \lambda \quad (3-16)$$

Neste caso, $\epsilon_r = \epsilon_0$ é a permissividade relativa média do espaço livre (ϵ_0). A permeabilidade relativa μ_r é assumida como unidade.

3.1.3.1 Polarização

Para o tratamento de problemas envolvendo absorção e retroespalhamento de onda eletromagnética pela matéria, a equação de Maxwell provê um ponto de partida conveniente porque define as leis fundamentais que governam todos os aspectos do eletromagnetismo, incluindo geração, propagação e interação da onda com a matéria. (ULABY, 1990, pag.1).

A polarização do vetor campo elétrico se refere a direção do vetor amplitude A , constante no tempo. Para uma onda polarizada linearmente, a direção de A é fixa. Para uma onda polarizada elípticamente, a direção A é em função do tempo e da rotação efetiva no eixo de propagação.

Toda onda eletromagnética é composta de dois campos, o elétrico (E) e magnético (M), sempre situados em planos ortogonais e variando em fase (0°). Esses campos se propagam em qualquer material isolante (dielétrico) em uma velocidade, cujo vetor está a 90° dos vetores de campo elétrico e magnético. No vácuo, essa velocidade é a da luz (adaptado de ANDRADE et. al., 2007c).

Quando uma onda eletromagnética é emitida por uma fonte, como uma antena, a energia é irradiada em todas as direções. Em um dado tempo t_0 , a fase dessa onda é dada por E e é constante em toda a superfície, dada por:

$$\Phi_0 = k' z - \omega t_0 + \Phi \quad (3-17)$$

Se a superfície plana possui amplitude constante, então a onda é referenciada como uma onda uniforme plana. No vácuo, este plano de propagação da velocidade da fase é dado por:

$$v_p = c = 1/\sqrt{\epsilon_0 \mu_0}$$

(3-18)

Onde “c” é a velocidade da luz e “ ϵ_0 ”, “ μ_0 ” são a permissividade e a permeabilidade do meio. Geralmente, a velocidade de propagação da onda eletromagnética em um meio é na ordem de 1 a 10 GHz.

A polarimetria é fundamental para se entender o comportamento das respostas dos alvos terrestres. O SAR do SIPAM possibilita a captação de dados nas quatro combinações disponíveis para a banda L (HH, HV, VH e VV), nas quais a primeira letra representa a polarização emitida e a segunda, a recebida.

A figura 3-3 demonstra a propagação da radiação eletromagnética em três campos vetoriais:

- Campo Elétrico (E);
- Campo Magnético (M);
- Vetor de Propagação (z);

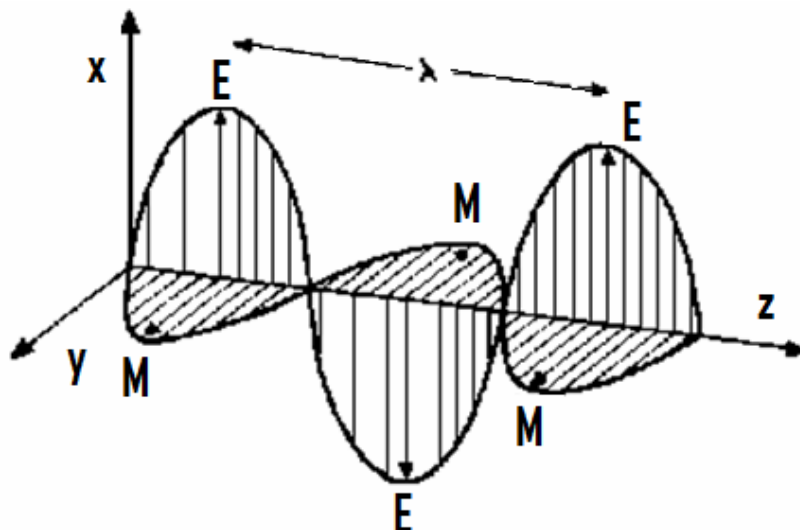


Figura 3-3 – Propagação da onda eletromagnética

Fonte: Curlander & McDonough (1991)

Para ondas planas e uniformes, esses três vetores são mutuamente ortogonais. Em superfícies planas (equifásicas), são representados por planos

paralelos, enquanto que em superfícies uniformes, a amplitude do campo elétrico é constante.

A figura 3-4 representa exemplos de polarizações de uma onda radiação eletromagnética (REM) horizontal (a) e vertical (b).

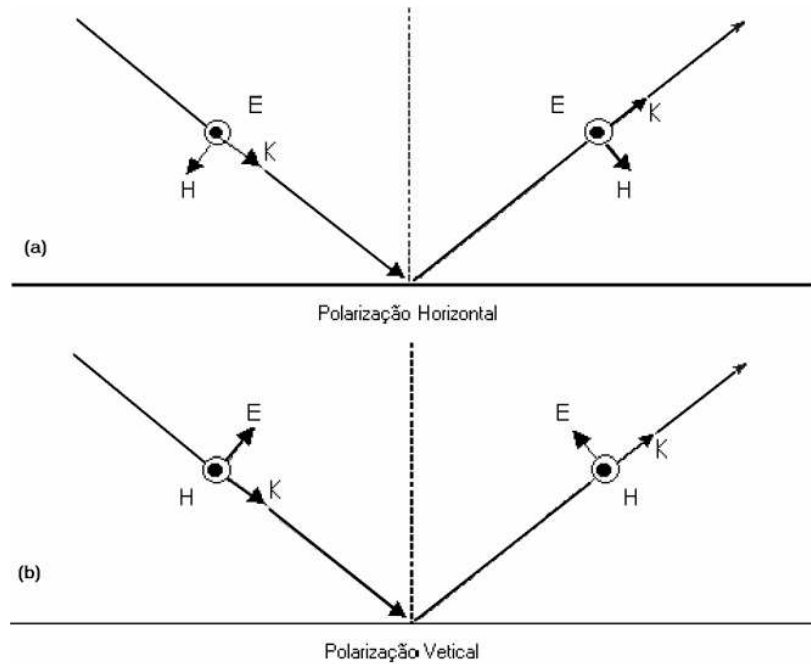


Figura 3-4 – Exemplos de polarizações de uma onda REM.

Fonte: Adaptada de Andrade & Veiga, 2002

A polarização na banda de maior comprimento de onda, a VV, faz com que estruturas verticais (troncos de árvores e postes) apresentem reflexão mais acentuada. Entretanto, estruturas horizontais são atravessadas e contribuem pouco no resultado final da imagem. Na polarização horizontal, as estruturas horizontais são mais bem destacadas.

Outros autores como Silva (2003) e Kramer et. al. (2001) citam que as polarizações cruzadas (VH ou HV) possuem alta correlação. Isoladamente, a polarização HV é a mais rica em detalhes e possibilita maior interação com as feições terrestres.

3.2 CARACTERÍSTICAS DO SENSOR MULTIPOLARIMÉTRICO AEROTRANSPORTADO BRASILEIRO

A seguir, explicam-se a aquisição das aeronaves pela FAB, algumas características básicas do avião, da antena e da geometria do imageamento SAR.

3.2.1 Aeronave de Sensoriamento Remoto

Beneficiada pelo Sistema de Proteção da Amazônia (SIPAM), a Aeronáutica adquiriu e passou a operar as aeronaves de sensoriamento remoto, cuja plataforma R-99, transporta três tipos de sensores: sistema ótico e infravermelho (OIS), radar de abertura sintética (SAR) e um sensor multiespectral (MSS), conforme figura 3-5. Cada um deles tem propósito e função diferentes, sendo que neste estudo optou-se por se trabalhar com o SAR multipolarimétrico.



Figura 3-5 - Localização dos sensores do R-99

Fonte: Andrade et. al.

As aeronaves de sensoriamento remoto são capazes de assumir a posição de vigilância, monitoramento do solo e dos recursos hídricos.

O SAR R-99 opera em duas frequências: banda L (1.28 GHz) e banda X (9.3 GHz). O subsistema da banda L tem a capacidade de transmitir e receber tanto na polarização vertical quanto na horizontal. O subsistema da banda X só transmite e recebe na polarização horizontal (ANDRADE & SANTA ROSA, 2007b).

Todos os dados gerados pelo sensor são denominados dados brutos, a partir dos quais há o processamento no *software* GSP (Ground Sistem Process), desenvolvido pelo fabricante canadense, ou no Pro-SAR, desenvolvido no Instituto de estudos Avançados da Aeronáutica (IEAV).

Além das características já citadas, o manual de operações do sistema SAR (2000) indica as seguintes condições para voo:

- 30.000' a 37.000' (9.149 a 11.277 metros) acima do nível médio do mar;
- velocidade em relação ao solo (*Ground Speed*) 330 a 390 knots ou 610 a 720 km/h;
- ângulo de cabragem de +3°(nose up), +/- 2° max;
- ângulo de rolagem +/- 2° max; e
- ângulo de derrapagem +/- 3° max.

A tabela 3-4 apresenta o resumo das principais características do SAR aerotransportado brasileiro:

Tabela - 3-4 Características do sensor SAR

Frequência central (GHz)	Banda L = 1.28 GHz \pm 100 MHz
	Banda X = 9.6 GHz \pm 300 MHz
Comprimento de onda central (cm)	Banda L = 23,4 cm
	Banda X = 3,12 cm
Largura de banda "bandwidth" (MHz)	3 metros = 50 MHz
	6 metros = 25 MHz
	18 metros = 8,33 MHz
	1,8 metros = 83,3 MHz
Polarização	Banda L = Lhh, Lv, Lv, Lv, Lhv
	Banda X = Xhh
Duração do pulso transmitido (P)	3 metros = 60 μ s
	6 metros = 40 μ s
	18 metros = 25 μ s
Potência de pico do transmissor – teórico (kW)	Banda L = 5
	Banda X = 10
Potência média (W)	Informação não disponível
Intervalo de repetição de pulso - PRI (segundos)	Varia em função do Modo de Operação.

Fonte: Manual de Operações SAR do SIPAM (2000)

3.2.2 Antena SAR

Uma antena pode ser definida como um dispositivo capaz de transmitir ou receber energia eletromagnética e possui três principais funções:



- a) Enviar um feixe de energia em determinada direção, a fim de aumentar a sensibilidade do radar nessa direção;
- b) Fornecer a direção do feixe, de modo que possa cobrir alguma área de interesse; e
- c) Permitir a medição angular de informações de modo que a direção de um alvo possa ser determinada.

No SAR do R-99, a antena pode gerar imagens dos seguintes tipos:

- *Image Exabyte Tape And Playback Display* - IETPD (processada a bordo, em tempo real, ou no solo);
- Bandas L e X (modo de mapeamento);

- SPOTSAR (modo de vigilância);
- Banda X (modo de vigilância);
- Wide Area Search (modo de vigilância);
- Air-to-Air (modo de vigilância);
- Modelos de Elevação (modo interferométrico).

Como comentamos, o SAR possui duas antenas principais, L e X. A figura 3-6 representa cada uma delas.



a) Antena SAR banda L

b) Antena SAR, banda X, monopulso

Figura 3-6 – Antenas SAR do R-99.

3.2.3 Geometria do Imageamento

Apesar de, no momento do imageamento, o usuário ter uma imagem radar como visada vertical, ela foi obtida a partir de uma visada oblíqua.

A figura 3-7 auxilia o entendimento da geometria básica de aquisição de imagens SAR. Nela, a plataforma se desloca transportando uma antena, em uma determinada altitude. A direção do voo da plataforma é conhecida como azimute e o tamanho da faixa imageada é medido em *range* (alcance). Na figura 3-7 utilizou-se uma imagem onde a antena fosse orientada paralela à linha de vôo.




Figura 3-7 – Geometria do imageamento SAR

Fonte: Adaptada de Oliver e Quegan (1998).

Tipicamente, a antena SAR é retangular, com dimensões $d_a \times d_e$ onde 'a' representa o azimute e 'e' a elevação, respectivamente. Estas dimensões são significantes porque determinam a área iluminada pela antena.

3.3 O RUÍDO SPECKLE

Existem vários ruídos em uma imagem SAR, o mais comum e característico é o ruído Speckle. O efeito deste tipo de ruído causa um aspecto granuloso às imagens, muito semelhante à textura "sal e pimenta" (Nepomuceno, 2003b.). É ocasionado no processo de interação da onda incidente com a superfície do terreno (retroespalhamento difuso). As ondas espalhadas e que alcançam a antena de recepção são somadas em direção e fase, o que resulta no sinal recebido

(Pinheiro, 1992). A maior presença deste ruído ocorre em áreas de maior intensidade do sinal (SANT'ANNA et. al., 2001).

O ruído Speckle é decorrente da natureza coerente do imageamento SAR. Ele dificulta a interpretação visual dos dados, assim como a classificação e segmentação destas imagens (SANT'ANNA et. al., 2001). Por conseguinte, é necessário reduzir este ruído para obter uma análise precisa e detalhada da cena. A redução pode ser feita de duas maneiras: através do processamento de multivisadas (*multi looks*) e/ou com a utilização de filtros.

O processamento de multivisadas consiste em processar cada visada independentemente para depois realizar uma operação de média aritmética em todas as visadas, resultando em uma única imagem mosaicada. A desvantagem neste processamento é a diminuição da resolução azimutal da imagem (quanto maior o número de visadas, menor a sua resolução azimutal).

Enquanto que o ruído das imagens ópticas é um fator aditivo na imagem (o sinal da cena somado a um ruído), as imagens SAR contêm ruídos mais complexos. O modelo mais aceito atualmente é o modelo multiplicativo e pode ser representado pela equação 3-19:

$$I(t) = R(t) \times S(t) \tag{3-19}$$

Onde:

$I(t)$ é a intensidade do ponto da superfície do pixel (t) ;

$R(t)$ é o retroespalhamento do alvo no pixel (t) ;

$S(t)$ é o ruído Speckle, independente de $R(t)$.

Sabendo-se que este tipo de efeito é relacionado ao tipo de sensor, existem métodos para reduzir a influência do ruído na extração de informações das imagens.

3.4 FILTRAGEM

Em uma imagem de Sensoriamento Remoto (SR), há o parâmetro denominado frequência espacial, que é quantidade de mudança de valores de número de cinza (NC) por unidade de distância, dentro da imagem. Se existirem poucas variações de NC em uma determinada área, esta recebe a denominação de área de baixa frequência; caso contrário, é denominada de alta frequência.

Nesse tipo de imagem, as feições são registradas no sensor em função da cobertura do terreno (solo, vegetação, rochas, área urbana, área de agricultura, etc.). Em cada uma delas, há a representatividade em NC da área imageada. Às vezes, acontecem áreas de contato entre feições (fronteiras). Essas fronteiras representam a transição de intervalo de nível de cinza entre uma feição e outra e são conhecidas como bordas (MATHER, 1999, p. 147 a 165).

O objetivo da filtragem é manipular as frequências (altas, médias ou baixas), de modo a realçar as feições de interesse ou corrigir as incorretas; para isso, adotam-se a utilização de filtros para a eliminação de ruídos, o realce de bordas ou a detecção de feições.

Um bom filtro é aquele que promove a menor perda da informação do dado original, fornece discriminação entre os alvos de cena, facilita a segmentação automática das imagens e permite a aplicação de realces clássicos desenvolvidos para as imagens geradas por sensores ópticos (Pinheiro, 1992, p.72).

Há duas maneiras para se aplicar a técnica de filtragem de frequência: o processo conhecido como convolução bidimensional, que opera no domínio espacial da imagem, ou a Análise de Fourier, que opera no domínio das frequências que compõe a imagem.

Em nosso estudo, trataremos da filtragem no domínio espacial, que nada mais é do que a transformação radiométrica pixel a pixel, para, no caso da imagem radar, a redução do ruído Speckle. Neste trabalho foram utilizados os filtros de Lee, Frost e MAP gamma adaptado.

3.4.1 Filtro de Lee

É um filtro que transforma o modelo multiplicativo em modelo aditivo, através da expansão em série de Taylor de 1ª ordem, em torno da média. Utiliza estatística local para minimizar o Erro Quadrático Médio (EQM), por meio do filtro de Wiener. É um filtro adaptativo e tem como característica a preservação de bordas. (SANTANA et. al., 2001; e MANSOURPOUR et. al., 2006).

O filtro de Lee é baseado no pressuposto de que a média e a variância do pixel de interesse é igual à média e variância de todos os pixels.

$$ND_{out} = [Média] + K [ND_{in} - Média] \quad (3-20)$$

Onde:

ND = número digital;

Média = média dos pixels na janela do filtro;

$$K = \frac{Var(x)}{[Média]^2 \sigma^2 + Var(x)} \quad (3-21)$$

e

$$Var(x) = \left(\frac{[var] + [média]^2}{[sigma]^2 + 1} \right) - [média]^2 \quad (3-22)$$

O sigma é baseado na probabilidade da distribuição Gaussiana. Supõe-se que Assume 95,5% das amostras aleatórias, dentro de uma faixa de desvio padrão 2.

3.4.2 Filtro de Frost

Segundo Mansourpour et Al (2006), “o filtro de Frost substitui o pixel de interesse com a soma ponderada dos valores dentro da janela (nxn) do movimento da janela de Kernel”. A ponderação de fatores decresce com a distância do pixel de

interesse. É um filtro convolucional e linear que minimiza o EQM. Neste filtro é incorporada a dependência dos pixels vizinhos (correlação exponencial entre os pixels). É adaptativo e preserva estruturas do tipo bordas. É apresentado na seguinte fórmula:

$$ND = \sum_{n=n} K \alpha e^{-\alpha/|t|} \quad (3-23)$$

Onde:

$$\alpha = (4/n\bar{\sigma}^2)(\sigma^2/\bar{I}^2)$$

K = constante de normalização;

\bar{I} = média local;

σ = variância local;

$\bar{\sigma}$ = variação do valor da variância na imagem;

$|t| = |X - X_0| + |Y - Y_0|$; e

n = tamanho da janela.

3.4.3 Filtro MAP gamma adaptado

O Máximo A Posteriori (MAP) é um filtro baseado no modelo do ruído multiplicativo, com os parâmetros de média e variância não-estacionários. Este filtro assume que o valor do ND original está entre o ND do pixel de interesse e o ND da janela de Kernel (MANSOURPOUR et. al., 2006).

O algoritmo de MAP gamma (MAPG) incorpora a hipótese de que, em áreas naturais, a seção transversal em gamma é a mais apropriada para representar o modelo distribuição, com a seguinte equação cúbica:

$$\hat{I}^3 - \bar{I}^2 + \sigma(\hat{I} - ND) = 0 \quad (3-24)$$

Onde:

\hat{I} = valor procurado;

\bar{I} = média local;

DN = valor de entrada; e

σ = variância da imagem original

A lógica MAPG maximiza a probabilidade a posteriori da função densidade, em relação à imagem original. Combina as propriedades geométricas e estatísticas da área local. A filtragem é controlada pelo coeficiente de variação e dos operadores de proporção geométrica.

O filtro MAPG, alterado por Santa Rosa e Menezes (1999), substitui o valor do pixel original pelo valor médio dos pixels da janela (caso os valores determinados pela função de MAP não estejam no intervalo entre a média da janela e o valor do pixel original). A nova condição substitui o valor do pixel original (Y_{ij}), pelo valor do pixel original mais ou menos o resíduo da janela (e).

$$Z_{ij} = Y_{ij} + e \quad (3-25)$$

Onde:

$$e = Y_{ij} + W_{ij} \text{ (média da janela cujo pixel central é } Y_{ij}\text{).}$$

3.5 REDES NEURAS ARTIFICIAIS

As redes neurais iniciaram com o trabalho pioneiro de McCulloch e Pitts (1943). McCulloch foi um psiquiatra e neuroanatomista; Pitts foi um prodígio matemático que se associou a McCulloch em 1942. Eles escreveram um artigo sobre o cálculo lógico das redes neurais que unificava os estudos das neurofisiologias e da lógica matemática. Em 1948, foi publicado o livro *Cybernetics de Wiener*, descrevendo alguns conceitos importantes sobre controle, comunicação e processamento estatístico de sinais. Em 1949, foi publicado por Hebb o livro *The Organization of Behavior*, no qual foi apresentada pela primeira vez uma formulação explícita de uma regra de aprendizagem fisiológica para a modificação de sináptica. Em 1956, Uttley demonstrou que uma rede com sinapses modificáveis pode aprender a classificar conjuntos simples de padrões binários, em classes correspondentes. Nesse ano, iniciou-se o trabalho sobre memória associativa de

Taylor. Outras contribuições significativas ao desenvolvimento inicial sobre memória associativa incluem os artigos de Anderson (1972), Kohonen (1972) e Nakato (1972), que de maneira independente e no mesmo ano introduziram a idéia de uma memória por matriz de correlação, baseada na regra de aprendizagem do produto externo.

Os anos seguintes foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar mais e mais artigos e livros que faziam previsões pouco confiáveis para a época, sobre máquinas tão poderosas quanto o cérebro humano que surgiriam em um curto espaço de tempo. Isto tirou quase toda a credibilidade dos estudos desta área.

Nos anos 80, foram feitas importantes contribuições em várias frentes à teoria e ao projeto de redes neurais e, com isso, houve um ressurgimento do interesse pelas redes neurais.

Grossberg (1980), baseado em seu trabalho inicial sobre aprendizagem competitiva, estabeleceu um novo princípio de auto-organização conhecido como a teoria da ressonância adaptativa (ART, *Adaptive Resonance Theory*).

Em 1987, ocorreu em São Francisco a primeira conferência de redes neurais em tempos modernos, a IEEE *International Conference on Neural Networks*, e também foi formada a *International Neural Networks Society* (INNS). A partir destes acontecimentos, decorreu a fundação do INNS journal em 1989, seguido do *Neural Computation* e do IEEE *Transactions on Neural Networks* em 1990.

Segundo Cabral (1999), “as redes neurais artificiais podem ser consideradas como sistemas de processamento de informações.”, ou seja, um conjunto de partes que se intercomunicam, inter-relacionam com um objetivo comum e, como em qualquer sistema, aceitam entradas e produzem saídas que são mais adequadas para esta ou aquela aplicação (HAYKIN, 2001, p. 63-69)

Sabe-se que não há limites para o que as redes neurais artificiais podem fazer. Uma de suas maiores habilidades é a associação genérica de padrões, que ocorre em virtude do funcionamento baseado nas redes neurais biológicas do cérebro humano, pois trabalham semelhantes a um sistema paralelo de

processamento, apesar de serem constituídas de neurônios individuais, capazes de realizar processamento de informações mais rápido do que qualquer computador que existe. (CABRAL, 1999, p.10).

3.5.1 Tipos e Classificação de Redes Neurais Artificiais

Segundo Cabral (1999), “existem diversos tipos de RNA e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado, que pode ser supervisionada ou não-supervisionada”.

No aprendizado supervisionado conjuntos de padrões de entrada e seus correspondentes padrões de saída são sucessivamente apresentados à rede. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado. Por exemplo: Boltzmann Machine, *Dynamic Programming Neural Network*, *perceptron*, *adaline* e *madaline*, *backpropagation*, são algumas dentre as dezenas de leis de aprendizagem supervisionada.

No aprendizado não-supervisionado, a rede “analisa” os conjuntos de dados apresentados, determina algumas propriedades do conjunto de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades de “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem.

Dentre os tipos de rede não-supervisionada, destacam-se:

- a) Perceptron simples proposta por Rosenblatt (1958);
- b) Rumelhart (1986) apresentou o modelo de Multi Layer Perceptron (MLP);
- c) As redes de Kohonen (1989). Também chamadas de redes SOM (*Self-Organizing Maps*) ou mapa auto-organizável; e
- d) Hopfield (1982) apresentou um modelo de rede recorrente.

3.5.2 Neurônio Biológico

Os neurônios biológicos são divididos em três seções: o *corpo celular*, os *dendritos* e os *axônios*, cada um com funções específicas, porém complementares (BRAGA et. al., 2007, p. 6). Os dendritos recebem as informações e as conduzem ao corpo celular, enquanto que os axônios transmitem as informações processadas a outros neurônios. O ponto de contato entre a terminação axônica e um neurônio é chamado de *sinapse*, que funcionam como válvulas e são capazes de controlar a transmissão do impulso. O final de cada terminação do axônio é denominado *telodentro*.

A figura 3-8 ilustra um neurônio biológico.

Braga (2007) complementa que “a capacidade de realizar funções complexas surge com a operação em paralelo de todos os neurônios do sistema nervoso”.




Figura 3-8 - Componentes do neurônio biológico

Fonte: Adaptada de Braga et. al.. (2007)

Segundo Kohonen e Makisara (1999), “o impulso de uma entrada depende das propriedades das conexões sinápticas”, a partir do qual o neurônio dispara ou não o impulso nervoso. Um único impulso não parece ter significado, pois não ocorrerá nenhum efeito nervoso.

3.5.3 Neurônio Artificial

O modelo proposto para representar o neurônio artificial foi idealizado por McCulloch e Pitts (MCP) e é uma simplificação do neurônio biológico (HAYKIN, 2001, p. 63; e BRAGA et. al., 2007, p. 8).

Segundo Queiroz (2004) & Haykin (2001), “o sistema do processamento de cada neurônio também pode ser representado em três etapas”. Cada uma delas tem sua importância dentro do processamento da informação. A seguir, são apresentadas as três etapas. A figura 3-9 apresenta um modelo não-linear de neurônio.

- 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).

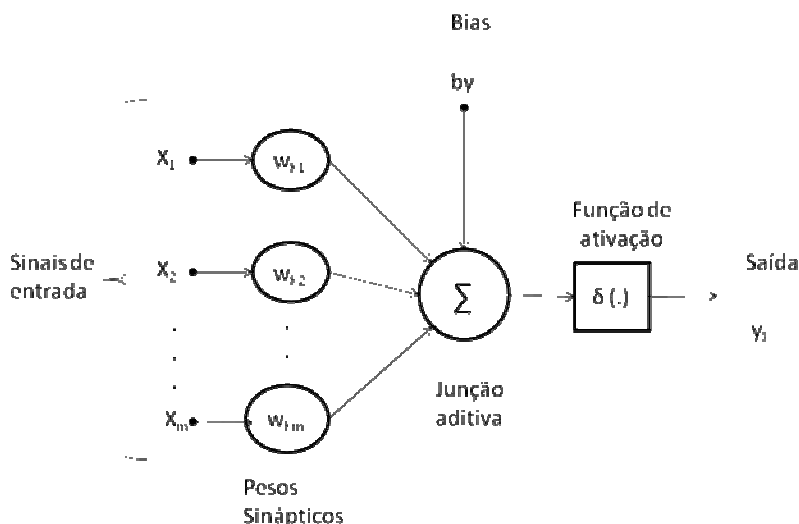


Figura 3-9 - Modelo não-linear de um neurônio.

Fonte: Haykin (2001) & Queiroz et. al.(2004).

O procedimento de soma pode ser expresso por:

$$S = \sum_{i=1}^n w_i x_i \quad (3-26)$$

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 da figura 3-9 inclui também “*bias*”, cujo propósito é o de 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).

Esses autores também descrevem a estrutura básica de uma rede neural (figura 3-10), associando-a a pesos na entrada das sinapses.




Figura 3-10 - Esquema de uma Rede Neural

Fonte: Queiroz et. al., 2004

O trabalho primordial realizado por 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.

3.5.4 Redes Neurais Artificiais Auto-organizáveis

Algumas RNAs possuem a capacidade de auto-organização. Neste estudo, assim como no classificador de SGRNA, priorizaremos as redes ART (do inglês *Adaptative Resonance Theory*) e as redes SOM (do inglês *Self-Organizing Maps*).

Em virtude da especificidade deste trabalho, as redes SOM, estudadas e desenvolvidas pelo Prof. Kohonen, serão mais detalhadas.

3.5.4.1 Redes SOM

Uma rede neural artificial auto-organizada possui uma característica que se destaca em relação às propriedades das redes com treinamento supervisionado em geral. Os pesos sinápticos dos neurônios que a compõem se ajustam ao longo da apresentação dos dados de entrada, sem a necessidade de supervisão externa (HAYKIN, 2001, p.483-524)

As redes mapas auto-organizáveis, SOM, também chamadas de mapas de características auto-organizáveis SOFM (do inglês *Self-Organizing Feature Maps*), foram desenvolvidas por Teuvo Kohonen na década de 1980 e utilizadas em diversos tipos de trabalho (Kohonen & Mäkisara, 1988; e Braga et. al. 2007, p. 98).

Um dos pontos importantes dessa rede é uma forte inspiração neurofisiológica, baseada no mapa topológico, presente no córtex cerebral (BRAGA et. al., 2007, p. 98).

Ao observar o funcionamento do cérebro humano, percebe-se que alguns neurônios estão espacialmente ordenados dentro de áreas específicas (fala, visão),

em vista disso, neurônios topologicamente próximos tendem a responder a padrões e estímulos semelhantes.

Segundo Cabral (1999), “o paradigma neural SOM se baseia no aprendizado competitivo e os neurônios formam um reticulado, cuja dimensão pode ser qualquer uma, dependendo de como ocorrer o treinamento”.

Segundo Kohonen & Mäkisara (1988), a rede SOM funciona basicamente da seguinte forma: quando um padrão de entrada **p** é apresentado, a rede procura a unidade mais parecida com **p**. Durante o treinamento, a rede aumenta a semelhança do neurônio escolhido e de seus vizinhos ao padrão **p**. Dessa forma, a rede constrói um mapa topológico onde neurônios que estão topologicamente próximos respondem de forma semelhante a padrões de entrada semelhantes.

3.5.4.1.1 Arquitetura da Rede SOM

Segundo Kohonen (1988), “nesse tipo de rede, os neurônios se organizam em uma grade ou reticulado, geralmente bidimensional, podendo algumas vezes ser unidimensional”. A grade bidimensional tem a forma de uma superfície plana, onde os neurônios de saída estão organizados em linhas e colunas; as camadas de entrada e saída estão totalmente conectadas; e o *feedback* (conhecido como chapéu mexicano) na camada de saída é apenas uma vizinhança de cada neurônio (excitação/inibição lateral). A figura 3-11 ilustra a arquitetura de uma rede SOM típica. Neste exemplo todas as entradas $\{X_0 \dots X_N\}$ estão conectadas com as saídas.




Figura 3-11 - Rede SOM típica.

Fonte: Adaptada de Haykin (2001)

Ao longo da fase de aprendizado, os neurônios progressivamente se ajustam aos vários padrões ou classes de vetores de entrada, de maneira tal que as relações topológicas entre as entradas se tornem compatíveis com o neurônio do reticulado. Dessa forma, um mapa de características *self-organizing* forma mapas topológicos de padrões de entrada, onde padrões semelhantes são detectados por neurônio próximos dentro do reticulado.

Como se pode observar na equação 3.27, o estado de ativação de um neurônio é determinado pela distância euclidiana entre seu peso e vetor de entrada.

$$Y_j = \sum_{i=1}^n \| x_i - w_{ji} \| \quad (3-27)$$

3.5.4.1.2 Treinamento

O treinamento (aprendizado) de uma rede neural pode ser supervisionado ou não-supervisionado. Em tese, são formados grupamentos de neurônios que funcionam como detectores de características. A partir daí, são gerados os mapas topográficos, em um processo cíclico de comparação de padrões de entrada com armazenados pelos neurônios.

- a) Aprendizado supervisionado: esse tipo de aprendizado é adequado para situações onde se conhecem os parâmetros de entrada e de saída da rede para um caso real; e
- b) Aprendizado não-supervisionado: a aplicação é mais indicada quando não se conhecem os valores dos parâmetros de saída.

A literatura chama atenção para treinamento, pois após a definição da topologia e dos parâmetros de controle, são realizados os cálculos para ajuste dos pesos, que proporcionarão o menor erro em relação aos dados originais. Nessa fase, devem ser tomados alguns cuidados para se assegurar a convergência da rede, evitando:

- a) *Overflow* nas variáveis responsáveis pelo cálculo dos erros; e
- b) Saturação dos neurônios: problema que ocorre quando um dos neurônios atinge valores muito próximos do limite da função de ativação.

Segundo Kohonen (1988), “o treinamento da rede SOM é competitivo e não-supervisionado”, embora o resultado gere condições de ser refinado e/ou rotulado com um processo supervisionado.

Segundo Braga et. al. (2007), “o algoritmo de treinamento original organiza os neurônios em vizinhanças locais e os neurônios competem entre si para ver quem gera a maior saída”. Definido o neurônio vencedor, tem o processo de atualização de pesos. Este procedimento caracteriza o treinamento competitivo da rede.

O que existe de particularidade nesse tipo de rede é que os pesos dos neurônios vizinhos ao vencedor também são atualizados. (CABRAL, 1999, p. 43-66).

Cabral (1999) também nos alerta que no início do treinamento, as vizinhanças de atualização são grandes, a ponto de abrangerem todo o reticulado, o que torna as direções dos pesos sinápticos correlatadas em todo o reticulado. Ao longo do treinamento, a redução do tamanho das vizinhanças favorece uma seletividade entre os padrões de entrada e a formação de regiões de maior atividade em torno do neurônio vencedor.

Considerando-se o reticulado como bidimensional, define-se:

Vetor de entrada:

$$x = [x_1 \dots x_p]^T \quad (3-28)$$

O vetor peso sináptico de cada neurônio da grade tem a mesma dimensão que o espaço de entrada, considerando que o vetor peso sináptico do neurônio “j” seja representado por:

$$W_j = [w_{j1} \dots w_{jp}]^T \quad (3-29)$$

Onde $j = 1, \dots, N$.

Sendo “p” a dimensão dos vetores de entrada e “N” e o número de neurônio do reticulado.

O melhor casamento, baseado na maximização do produto interno $w_j^T x$, é matematicamente equivalente a minimizar a distância euclidiana entre os vetores “x” e “w”. Usando-se o índice $i(x)$ para identificar o neurônio que melhor casa com o vetor de entrada “x”, pode-se determinar $i(x)$, aplicando-se a condição a seguir (HAYKIN, 2001, p 484-524):

$$i(x) = \arg \left(\min_j \|x - w_j\| \right) \quad (3-30)$$

Nesse caso, a topologia é determinada pela definição da vizinhança $V(i(x), r)$ de um neurônio $i(x)$ de raio r, medido segundo a métrica utilizada sobre o reticulado. Para se obter o melhor resultado, r é reduzido a cada interação.

Sabe-se que durante o treinamento, a taxa de aprendizado e o raio da vizinhança são continuamente decrementados. A equação 3.31 ilustra como são atualizados os pesos da unidade vencedora e daquelas situadas na sua vizinhança:

$$W_{ji}(t+1) = \begin{cases} W_{ji}(t) + n(t)(x_i(t) - W_{ji}(t)), & \text{se } j \in \Lambda(t) \\ W_{ji}(t), & \text{caso contrário} \end{cases} \quad (3-31)$$

Onde: $w_{ij}(t)$ é o peso da conexão entre o elemento de entrada $x_i(t)$ e o neurônio j, $n(t)$ é a taxa de aprendizado e Λ é a vizinhança do neurônio vencedor, tudo no instante de tempo t (BRAGA et. al., 2007, p.102).

O neurônio vencedor localiza o centro de uma vizinhança topológica de neurônios cooperativos. Em um sentido qualitativo, a vizinhança topológica gaussiana (equação 3.32) é mais biologicamente apropriada que uma vizinhança retangular (HAYKIN, 2001, p. 483).

A seguir, é apresentada a função gaussiana para uma escolha típica da vizinhança topológica h_{ij} , centrada no neurônio vencedor “i” e que contém o conjunto de neurônios excitados, sendo o neurônio típico deste conjunto representado por “j”.

$$h_{j,i(x)} = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right) \quad (3-32)$$

Onde σ é a ‘largura efetiva’ da vizinhança topológica.

O resultado do treinamento da rede SOM é influenciado por três fatores:

- Pela taxa de aprendizado;
- Pela taxa de redução da região de vizinhança (decaimento da vizinhança); e
- Pelo formato da região de vizinhança.

Para que a cooperação entre neurônios vizinhos se mantenha, é necessário que a vizinhança topológica $h_{j,i}$ seja dependente da distância lateral $d_{j,i}$ entre o neurônio vencedor “i” e o neurônio excitado “j” no espaço de saída, em vez de ser dependente de alguma medida de distância no espaço de entrada original (HAYKIN, 2001, p. 483).

Cabral (1999) conclui que o mapa de atributos final apresenta características importantes dos dados de entrada, nas quais mostram a capacidade da rede de comprimir, codificar e classificar padrões.

3.5.5 Algoritmos Genéticos

O desempenho obtido pelas RNA's depende da topologia destas redes (tamanho, estrutura e conexões), assim como dos parâmetros de seu algoritmo de treinamento (taxa de aprendizado). A determinação da rede (o que inclui a arquitetura e os, parâmetros de aprendizado) afeta a velocidade e a eficiência do

processo de aprendizado, tolerância a falhas e ruídos e capacidade de generalização.

Segundo Nepomuceno (2003), “várias técnicas para automação do projeto de redes neurais vêm sendo desenvolvidas visando resolver o problema de otimização de arquitetura de rede neural”. Uma destas técnicas envolve a utilização de algoritmos genéticos.

Algoritmos Genéticos (AG's) são algoritmos de otimização e busca baseados nos mecanismos de seleção natural genética (BRAGA et. al., 2007, p.118).

A diferença desse tipo de método de otimização de busca, em relação aos convencionais, é que os algoritmos genéticos trabalham com um conjunto de soluções possíveis, enquanto que aqueles avaliam uma solução a cada instante.

Segundo Braga et. al. (2007), “AG's não garantem uma solução ótima, mas geralmente encontram soluções quase ótimas, em um tempo aceitável”.

Os princípios da natureza nos quais os GAs se inspiram são simples. De acordo com a teoria de C. Darwin, o princípio de seleção privilegia os indivíduos mais aptos com maior longevidade e, portanto, com maior probabilidade de reprodução. Indivíduos com mais descendentes têm mais chance de perpetuarem seus códigos genéticos nas próximas gerações. Tais códigos genéticos constituem a identidade de cada indivíduo e estão representados nos cromossoma. (PACHECO,1999, p.2),

Esses princípios são imitados na construção de um algoritmo computacional que buscam uma melhor solução para determinado problema, através de evolução de populações codificadas por meio de cromossomas artificiais.

Segundo Pacheco (1999), “em AG's um cromossoma é uma estrutura de dados que representa uma das possíveis soluções do espaço de busca do problema”. Cromossomas são então submetidos a um processo evolutivo que envolve avaliação, seleção, recombinação sexual (crossover) e mutação. Após vários ciclos de evolução a população deverá conter indivíduos mais aptos.

3.5.5.1 Parâmetros que influenciam o algoritmo genético

Segundo Silva (2003) e Braga (2007), “alguns parâmetros influenciam no comportamento dos AG, fins estabelecê-los conforme as necessidades do problema e dos recursos disponíveis”.

Dentre esses parâmetros, podemos citar:

- a) Tamanho da População: o tamanho da população afeta o desempenho global e a eficiência dos AG's. Uma população pequena oferece uma pequena cobertura do espaço de busca, causando uma queda no desempenho. Uma grande população fornece uma melhor cobertura do domínio do problema e previne a convergência prematura para soluções locais. Entretanto, com uma grande população tornam-se necessários recursos computacionais maiores, ou um tempo maior de processamento do problema. Silva (2003) informa que populações entre 30 e 100 indivíduos geraram resultados aceitáveis, para uma aplicação e dimensões específicas.
- b) Taxa de Cruzamento (crossing-over): quanto maior for essa taxa, mais rapidamente novas estruturas serão introduzidas na população. Entretanto, isto pode gerar um efeito indesejado, pois a maior parte da população será substituída podendo ocorrer perda de estruturas de alta aptidão. Com um valor baixo, o algoritmo pode tornar-se muito lento;
- c) Taxa de Mutação: uma baixa taxa de mutação previne que uma dada posição fique estagnada em um valor, além de possibilitar que se chegue a qualquer ponto do espaço de busca. Com uma taxa muito alta a busca se torna essencialmente aleatória; e
- d) Quantidade máxima de geração: controla a porcentagem da população que será substituída durante a próxima geração.

3.6 CLASSIFICAÇÃO DE IMAGENS

Segundo Mather (2004), “O melhor sistema de interpretação de imagens que possuímos é a combinação de nossos olhos com o nosso cérebro”. Nesse sistema, o sinal é percebido pelo sensor, convertido em pulsos elétricos e impulsionados diretamente ao cérebro, onde as imagens são interpretadas em tempo real.

Segundo Mather (2004), “o processo de classificação consiste em dois estágios. O primeiro é o reconhecimento de categorias do mundo real dos objetos. O segundo é nomear as entidades classificadas.”

Baseados nessas idéias, pesquisadores e estudiosos desenvolveram um modelo de classificador que pudesse agir semelhante ao processo de classificação utilizado pelo cérebro, 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, (GONÇALVES, 1996)

No caso da classificação não-supervisionada, os pixels de uma imagem são alocados em classes sem que o usuário tenha conhecimento prévio de sua existência (NOVO, 2008).

Neste trabalho utilizou-se o programa de Rede Neural Artificial desenvolvido por Silva (2003), em sua tese de Doutorado. Nele, o algoritmo genético permite aperfeiçoar os resultados da rede neural.

3.7 ÍNDICE DE KAPPA

Segundo Pinheiro (2003) & Mather (2004), “estatística Kappa é um método muito utilizado na análise da exatidão de mapas temáticos”. A estatística Kappa possui a vantagem de incluir, no cálculo do seu coeficiente, todos os elementos da

matriz de confusão, e não apenas os elementos da diagonal principal, como na exatidão em global.

O índice de Kappa é originado da matriz de confusão. Os elementos dessa matriz são calculados da seguinte formulação:

$$M(C_i, C_j) = \sum_{\{ \forall (x, y) \in n : y = C_i \}} \|h(x) = C_j\| \quad (3-33)$$

$$\{ \forall (x, y) \in n : y = C_i \}$$

Onde:

M = matriz de confusão de k elementos

C_i = linha da matriz

C_j = coluna da matriz

h – hipótese

n = conjunto de amostras analisadas

A tabela 3- 5 é um exemplo de modelo de construção da matriz de confusão.

Tabela 3-5 – Modelo de Matriz de confusão

Classe	verdadeira C ₁	verdadeira C ₂	verdadeira C ₃	verdadeira C _k
temática C ₁	M(C ₁ , C ₁)	M(C ₁ , C ₂)	M(C ₁ , C ₃)	M(C ₁ , C _k)
temática C ₂	M(C ₂ , C ₁)	M(C ₂ , C ₂)	M(C ₂ , C ₃)	M(C ₂ , C _k)
temática C ₃	M(C ₃ , C ₁)	M(C ₃ , C ₂)	M(C ₃ , C ₃)	M(C ₃ , C _k)
.
.
.
temática C _k	M(C _k , C ₁)	M(C _k , C ₂)	M(C _k , C ₃)	M(C _k , C _k)

É importante considerar que, ao interpretar uma matriz de confusão do tipo apresentado na tabela 3-5, do ponto de vista de uma classe particular, o avaliador deve entender que as diferentes precisões de classe são resultados do número de pixels corretos para uma determinada classe, dividido pelo número total de pixels da classe de referência terrestre ou o número total de pixels que classificador atribuiu à classe.

Com a matriz de confusão montada, é possível calcular o índice de Kappa (\hat{K}), conforme a equação 3.34:

$$\hat{k} = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{n^2 - \sum_{i=1}^r (x_{i+} x_{+i})} \quad (3-34)$$

Onde:

r = número de linhas da matriz quadrada;

x_{ii} = entrada da diagonal principal da matriz de confusão

x_{i+} = total de observações das linhas,

x_{+i} = total de observações das colunas,

n = representa o número total e observações.

Para se determinar a acurácia global ou da matriz de confusão, utiliza-se a seguinte fórmula:

$$Acuráciaglobal = \frac{\sum_{i=1}^r x_{ii}}{n} \quad (3-35)$$

Onde:

x_{ii} = entrada da diagonal principal da matriz de confusão

n = número total de observações

A tabela 3-6 descreve a qualidade da classificação e valores da estatística de Kappa.

Tabela 3-6 - KAPPA

Valor de <i>Kappa</i>	Qualidade do mapa temático
< 0,00	Péssima
0,00-0,20	Ruim
0,20-0,40	Razoável
0,40-0,60	Boa
0,60-0,80	Muito Boa
0,80-1,00	Excelente

Adaptado de Landis e Koch (1977)

Da matriz de confusão, também se extrai a variância $Var(\hat{K})$, fins utiliza-la no teste estatístico. A equação 3.35 descreve a formulação de $Var(\hat{K})$:

$$Var(\hat{k}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2-\theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4-4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (3-36)$$

Onde

$$\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (3-37)$$

$$\theta_2 = \frac{\sum_{i=1}^c x_{i+} x_{+i}}{n^2} \quad (3-38)$$

$$\theta_3 = \sum_{i=1}^c x_{ii} (x_{i+} + x_{+i}) / n^2 \quad (3-39)$$

$$\theta_4 = \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j+} + x_{+i})^2 / n^3 \quad (3-40)$$

Com os valores \hat{K} e $\text{Var}(\hat{K})$, testam-se os dados da classificação com os de referência, pois é necessário confirmar se há concordância ou não entre os dados.

Assim, duas hipóteses são formuladas, com nível de significância de 5%:

$H_0 = K_1 = K_2$ (hipótese nula)

$H_1 = K_1 > K_2$ (hipótese alternativa)

$$Z = \frac{(\hat{\kappa}_1 - \hat{\kappa}_2) - (\kappa_1 - \kappa_2)}{\sqrt{\text{Var}(\hat{\kappa}_1) + \text{Var}(\hat{\kappa}_2)}} \sim N(0,1) \quad (3-41)$$

4 MATERIAIS E MÉTODO

Neste capítulo, apresentam-se os materiais utilizados na pesquisa, descreve-se o tipo da pesquisa desenvolvida, os fatores que a motivaram e como ela foi realizada.

Resumidamente, há uma descrição das quatro etapas principais: aquisição das imagens SAR; processamento dos dados de sensoriamento remoto; classificação das imagens; e tratamento estatístico dos resultados.

4.1 MATERIAIS

Os materiais utilizados neste trabalho são produtos do sensor SAR do SIVAM, coletados na Região Administrativa de Planaltina. Os dados foram processados no *software Environment for Visualizing Images* ENVI 4.5, licenciado para o Comando da Aeronáutica; posteriormente, fez-se uso de ambiente computacional do *software Matriz Laboratory* (MatLab) para a filtragem do MAP gamma; e, finalmente, os dados foram classificados no *software* de Síntese Genética de Redes Neurais Artificiais (SGRNA), desenvolvido pelo Prof. Dr. Nilton Correa da Silva, em sua tese de doutorado.

4.1.1 Aquisição de dados

Inicialmente, descrevem-se as principais etapas da coleta de dados e alguns dados técnicos e operacionais do voo.

O voo para aquisição dos dados foi realizado às 17:00 h do dia 30 de abril de 2010, no modo de aquisição Quad L + Single X {Lv_v, Lv_h, Lh_h, Lh_v, XStrip}, nos comprimentos de onda (λ) de 23 cm, para a banda L, e 3 cm para a banda X.

4.1.1.1 Planejamento do voo:

Neste trabalho, em virtude de acordos pré-estabelecidos, houve interação direta com o Esquadrão Guardião, codinome dado ao 2º/6º Grupo de Aviação da

FAB, na captação dos dados. Segundo os representantes daquele Esquadrão, sediado em Anápolis-GO, o voo foi planejado da seguinte maneira:

- a) Tempo total para o cumprimento da missão: 1 dia;
- b) Área abrangida: Região Administrativa de Planaltina - DF;
- c) Esforço Aéreo planejado: 02:30h;
- d) Número de faixas de imageamento: 5;
- e) Fitas necessárias: 02 DCRSi e 01 Exabyte;

A figura 4-1 representa o planejamento do voo, com a área total imageada de 2.280 Km².




Figura 4-1 - Planejamento do voo do R-99SAR

4.2 MÉTODO

Este capítulo descreve como o processo de obtenção de resultados foi seguido. Os primeiros subtópicos descrevem o tipo de pesquisa e a escolha das amostras. A partir daí, o método é explorado com mais eficiência e eficácia.

4.2.1 Tipo de pesquisa

Segundo a taxionomia proposta por Vergara (2004), a pesquisa foi realizada sob dois aspectos:

- a) Quanto aos fins: a pesquisa se definiu aplicada, porque é real a necessidade da Força Aérea em desenvolver técnicas de processamento digital de imagens para os produtos da plataforma R-99, em virtude de ser um radar canadense e da necessidade de aperfeiçoamento da tecnologia de aquisição de dado e na interpretação das imagens.
- b) Quanto aos meios: a pesquisa de investigação foi feita em consultas aos manuais do SAR, bibliografia específica de redes neurais artificiais e em visitas a área de estudo. Desta forma, é classificada como: documental, bibliográfica e de campo.

A pesquisa bibliográfica foi realizada em teses, livros, revistas especializadas e dados pertinentes ao assunto.

A Pesquisa documental sobre o SAR do R-99 foi realizada nos arquivos do Comando-Geral de Operações Aéreas (COMGAR), onde se encontram os manuais, relatórios e outros documentos publicados sobre o radar.

4.2.1.1 Universo e amostra

O universo da pesquisa foi a Região Administrativa de Planaltina-DF, sendo que a amostra foi direcionada a três grupos de análise: o primeiro grupo corresponde a regiões onde há predominância de cerrado, no caso o Parque de Preservação das Águas Emendadas; o segundo, uma amostra de regiões de agricultura; e o terceiro, composto de área urbana.

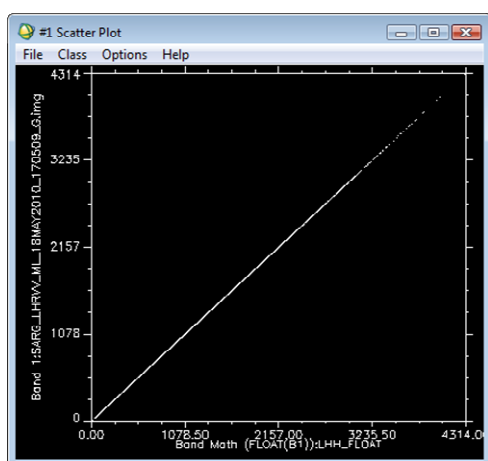
4.2.2 Pré-processamento digital das imagens.

4.2.2.1 Transformação de formato de dado

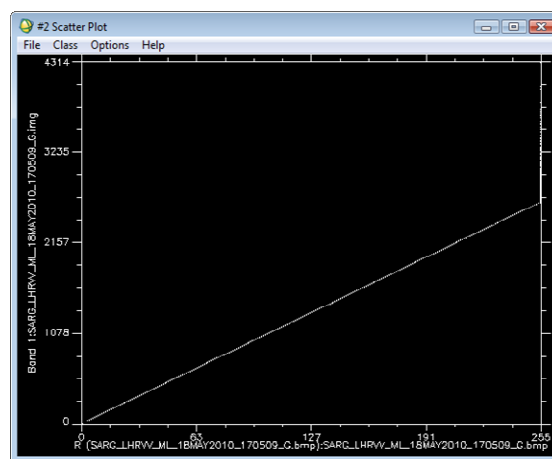
Inicialmente, os dados brutos são gravados em fitas magnéticas. No solo, em estações de processamento localizadas em Anápolis-GO, os dados receberam o pré-processamento inicial, onde foram inseridos o posicionamento geográfico e o georreferenciamento; após isso, os dados foram compilados por faixa, em forma de moisaco.

O SIPAM disponibiliza os dados em um formato *unsigned integer* (16 bits). Inicialmente, isso dificultou a leitura do dado pelo *software* de SGRNA, pois este tipo de formato não estava disponível para leitura. Diante disso, buscou-se preservar o máximo de detalhes dos dados, transformando-os em *Floating-point* (32 bits). Este procedimento foi feito no ENVI, utilizando a função de transformação. No menu do ENVI, acessar *basic tools* e *band math*. Escrever a função float (B1), onde B1 é a imagem que será convertida. Realizar o processamento e salvar o arquivo.

Finalmente, fez-se a comparação entre a os dados no formato *Unsigned integer* (16 bits) e *Floating-point* (32 bits), bem como *Unsigned integer* (16 bits), formato compatível para leitura do *software* (figura 4-2).



a) Correlação entre os formatos *Unsigned integer* (16 bits) e *Floating-point* (32 bits)



b) Correlação entre os formatos *Unsigned integer* (16 bits) e bmp

Figura 4-2 - Comparação entre formatos

4.2.2.2 Calibração dos dados em amplitude.

Sabe-se que as relações de potência são expressas em termos de notação logarítmica, denominada decibel (dB). A utilização desta notação nos permite adicionar e subtrair ganhos e perdas ao longo dos blocos que compõem um sistema, ao invés de multiplicá-los e dividi-los, simplificando bastante a análise.

Como o interesse é apenas expressarmos uma relação de tensão, ao invés de uma reação de potência, utilizamos a seguinte fórmula:

$$I = 20 \times \log(b1) + F \quad (4-1)$$

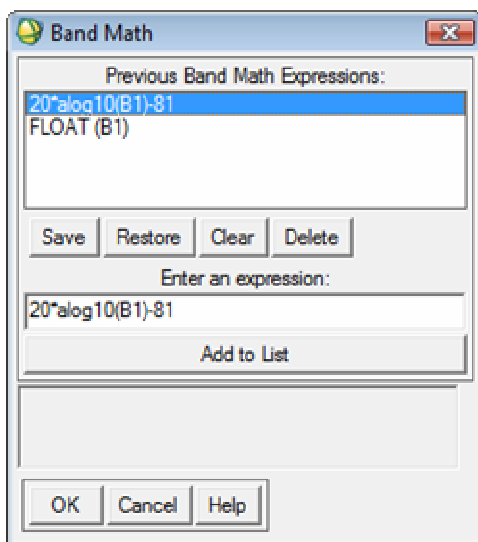
Onde:

I = imagem em amplitude

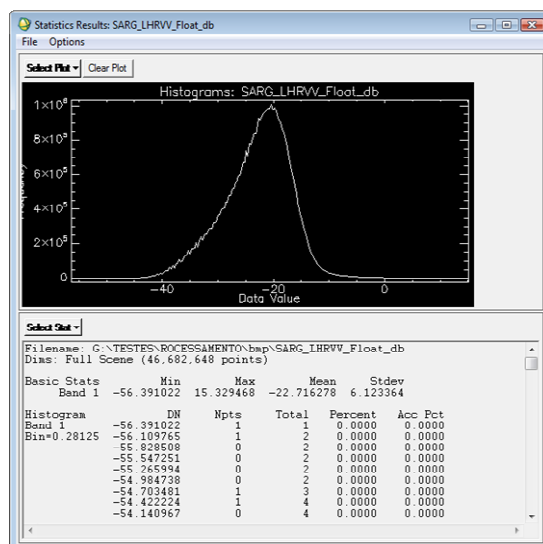
b1 = matriz de pixel estudada e

F = constante para calibração dos dados, devido como - 81 dB. (manual de operações do R99/SAR, 2000).

O processamento (figura 4-3) envolve apenas duas operações matemáticas, como segue:



a) Transformação dos dados em dB.



b) Histograma dos dados transformados em dB

Figura 4-3 Transformação de dados em dB.

A seguir, apresenta-se a correlação entre a imagem antes da calibração e após a calibração (figura 16).




Figura 4-4 Correlação entre as imagens antes e após a calibração.

Após a calibração dos dados, é necessário que os valores sejam novamente transformados em amplitude (V). Isso se fez, utilizando a equação anti-logaritma (figura 17), na qual se usou: $10^{(b2/20)}$, onde: b2 é a matriz de pixel com o dado de calibração da antena.

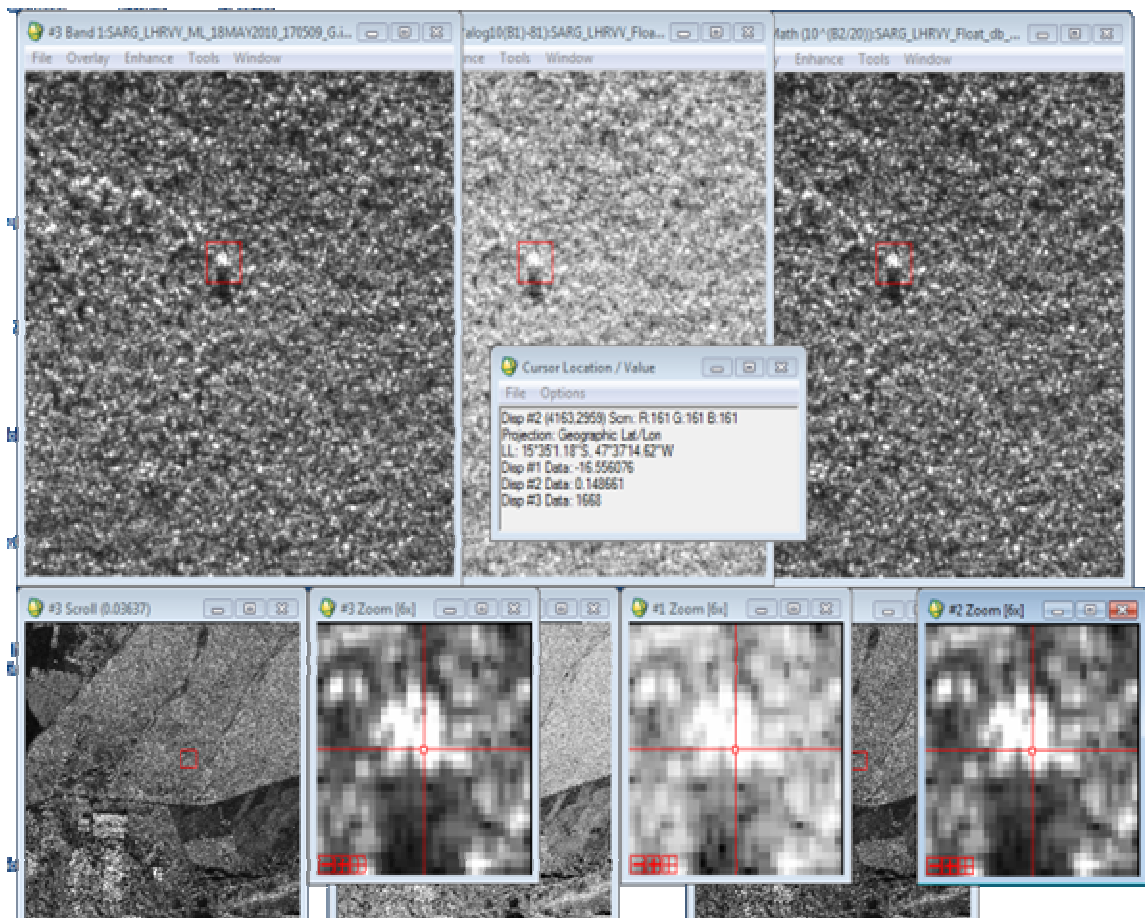


Figura 4-5 Comparação do ND do pixel, após a calibração.

4.2.2.3 Filtragem dos dados

As imagens foram filtradas uma a uma. Primeiramente, utilizou-se o software ENVI para o processamento com os filtros de Lee e Frost e, depois, o software MatLab para filtrar as imagens com MAP gamma, o erro quadrático médio e a relação sinal ruído. Todos os filtros foram testados nas janelas 3x3, 5x5 e 7x7.

a) Estimativa do Erro Médio Quadrático (MSE - *Mean Square Error*), que é baseada na média entre amostras;

$$MSE = \frac{1}{k} \sum_{i=1}^k (\hat{s}_i - s_i) \quad (4-2)$$

Onde:

\hat{s} = imagem filtrada

s = imagem original

K = tamanho da imagem

Em virtude do processamento SAR disponibilizar apenas imagens com o ruído, para efeito do estudo do MSE, utilizou-se a imagem original do sensor (com ruído) e a imagem pós-filtrada.

b) A Relação sinal ruído (SNR – *signal noise ratio*). Em imagens SAR, há interesse em suprimir o ruído speckle, ao mesmo tempo em que se preservam as bordas e as estruturas lineares da imagem original, por isso, é interessante conhecer a relação originada entre o sinal e o ruído da imagem.

$$SNR = 10 \log_{10} \left(\frac{\sum_{i=1}^k s_i^2}{\sum_{i=1}^k (\hat{s}_i - s_i^2)} \right) \quad (4-3)$$

c) parâmetro β : é utilizado para análise de preservação de bordas (Mansourpour, 2006).

$$\beta = \frac{\Gamma(\Delta S - \Delta \hat{S}, \Delta \hat{S} - \Delta(\bar{\hat{S}}))}{\sqrt{\Gamma(\Delta S - \Delta(\bar{S}), \Delta S - \Delta(\bar{S})) \Gamma(\Delta \hat{S} - \Delta(\bar{\hat{S}}), \Delta \hat{S} - \Delta(\bar{\hat{S}}))}} \quad (4-4)$$

Onde:

ΔS e $\Delta \hat{S}$ é um filtro passa-alta com versão S e \hat{S} , respectivamente, obtido com janela de 3x3 do operador Laplaciano. O filtro Laplaciano passa-alta utilizado neste propósito é apresentado como segue:

$$FiltroLaplaciano = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (4-5)$$

O operador Γ denota:

$$\Gamma(S_1 - S_2) = \sum_{i=1}^k S_{1_i} S_{2_i} \quad (4-6)$$

A correlação medida de β deve ser próxima a 1 na análise de preservação de bordas.

Os resultados foram apresentados em forma de tabelas e gráficos.

A partir dos resultados obtidos na filtragem, iniciou-se a etapa de classificação das imagens.

4.2.3 Classificação dos dados da banda L

O classificador SGRNA é não-supervisionado e utiliza a síntese genética para otimizar os resultados. Foi inicialmente escrito na linguagem C++, é bastante simples e prático de usar. O SGRNA lê arquivos nos formatos tif, jpeg, jpeg 2000, png, float point e bmp.

A figura 4-6 apresenta a tela inicial do classificador, a qual concede ao usuário a possibilidade de trabalhar com as configurações do algoritmo genético, inserir dados, filtrar imagem, realizar otimização dos dados e conhecer informações dos desenvolvedores do classificador.

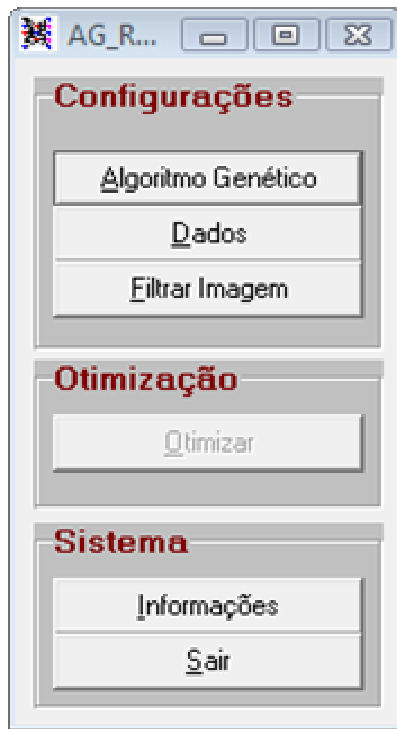


Figura 4-6 - Tela inicial do classificador SGRNA

A figura 4-7 é a tela que permite ao usuário inserir os parâmetros da otimização genética; escolher do tipo de rede neural; e manipular os parâmetros da rede escolhida, no caso a rede SOM.

Configuração dos Parâmetros da Otimização Genética

Probabilidades:
 Crossing-Over...: 0.6
 Mutação.....: 0.002

Complexidade Algorítmica:
 População.....: 100
 Qtde. Máxima de Gerações: 50

Rede Neural:
 ART 2 Fuzzy ART SOM

Parâmetros SOM

Descrição	Qtde. Bits	V.Mínimo	V.Máximo	Precisão
Taxa de Aprendizado	9	0.489	1	0.001
Decaimento da Taxa de Aprendizado	9	0	0.511	0.001
Decaimento da Vizinhança	9	0	0.511	0.001
Qtde. de Linhas do Mapa SOM	2	1	4	1
Qtde. de Colunas do Mapa SOM	2	1	4	1
Sequência de Treinamento	8	0	255	1

Ajustar Parâmetros

OK Cancela

Figura 4-7 - Tela de escolha de parâmetros

Para utilização do sistema, o usuário deve inserir o dado para ser otimizado pelo programa, conforme figura 4-8.

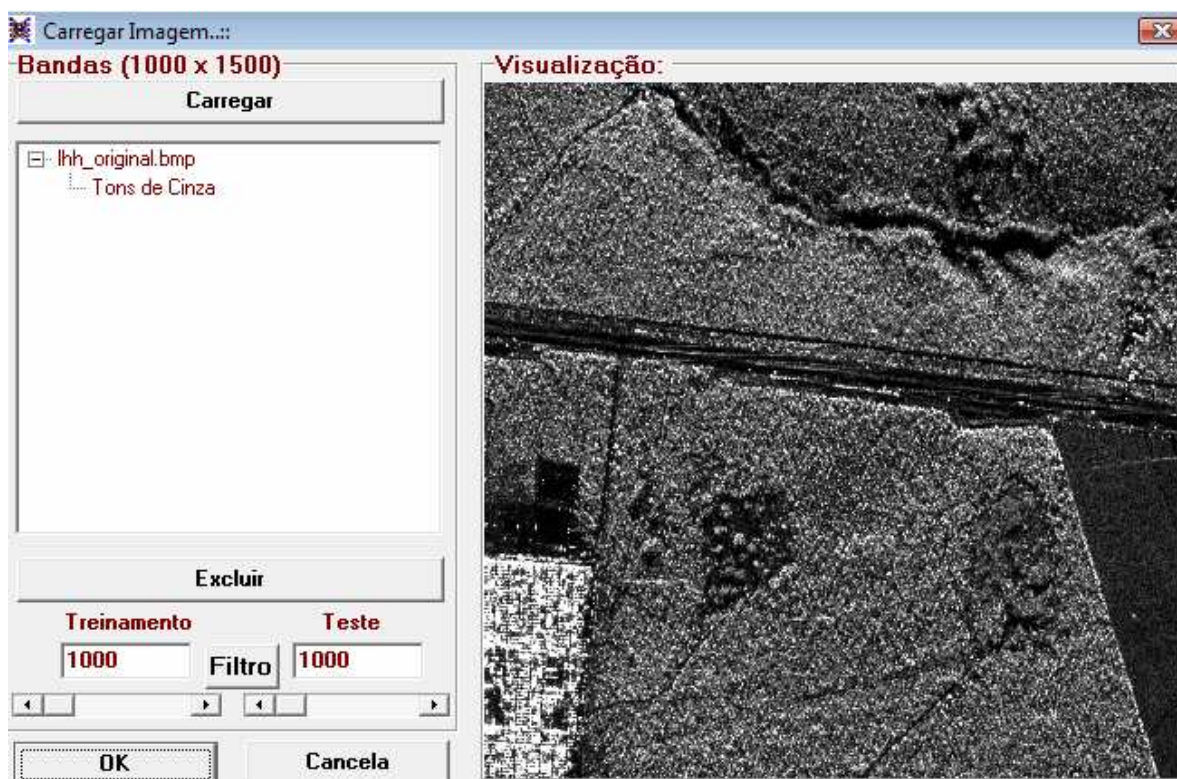


Figura 4-8 - Inserção de dados no SGRNA

O trabalho foi desenvolvido, com a inserção dos parâmetros contidos na tabela 4-1.

Tabela 4-1 - Parâmetros iniciais do AG e da rede SOM

Configuração dos parâmetros da Otimização genética					
Dados de treinamento		Probabilidades		Complexidade algorítmica	
Treinamento	1000	Crossover	0.6	População	100
Teste	1000	Mutação	0.002	Qde. Max gerações	50
Parâmetros de SOM					
Descrição	Qtde Bits	V. Mínimo	V. Máximo	Precisão	
Taxa de Aprendizado	9	0,489	1	0,001	
Decaimento da Taxa de Aprendizado	9	0	0,511	0,001	
Decaimento da Vizinhança	9	0	0,511	0,001	
Qtde. de Linhas do Mapa SOM	2	1	4	1	
Qtde. de Colunas do Mapa SOM	2	1	4	1	
Sequência de treinamento	8	0	255	1	

Segundo Silva (2003), a rede de Kohonen (SOM) apresenta os seguintes parâmetros: os três primeiros genes da tabela 4-1 (taxa de aprendizado, decaimento da taxa de aprendizado e decaimento da vizinhança) são taxas, cujos valores podem

variar de 0 (zero) e 1 (um); o quarto e quinto genes (quantidade de linhas e colunas do mapa SOM) são utilizados para definir a geometria bidimensional do mapa; e o sexto gene (sequência de treinamento) define ordens de apresentação do conjunto de treinamento à RNA, nos ciclos de treinamentos.

Após as etapas iniciais, o sistema realizou a otimização dos dados e o classificador sugeriu uma resposta de classificação, conforme os parâmetros do algoritmo genético e rede Neural artificial. Essa resposta pode ser ajustada de acordo com a quantidade de classes que se deseja obter.

A figura 4-9 representa o resultado desse processo. Neste caso, a classificação otimizada gerou 12 classes para a imagem SAR, na banda L, polarização HH.

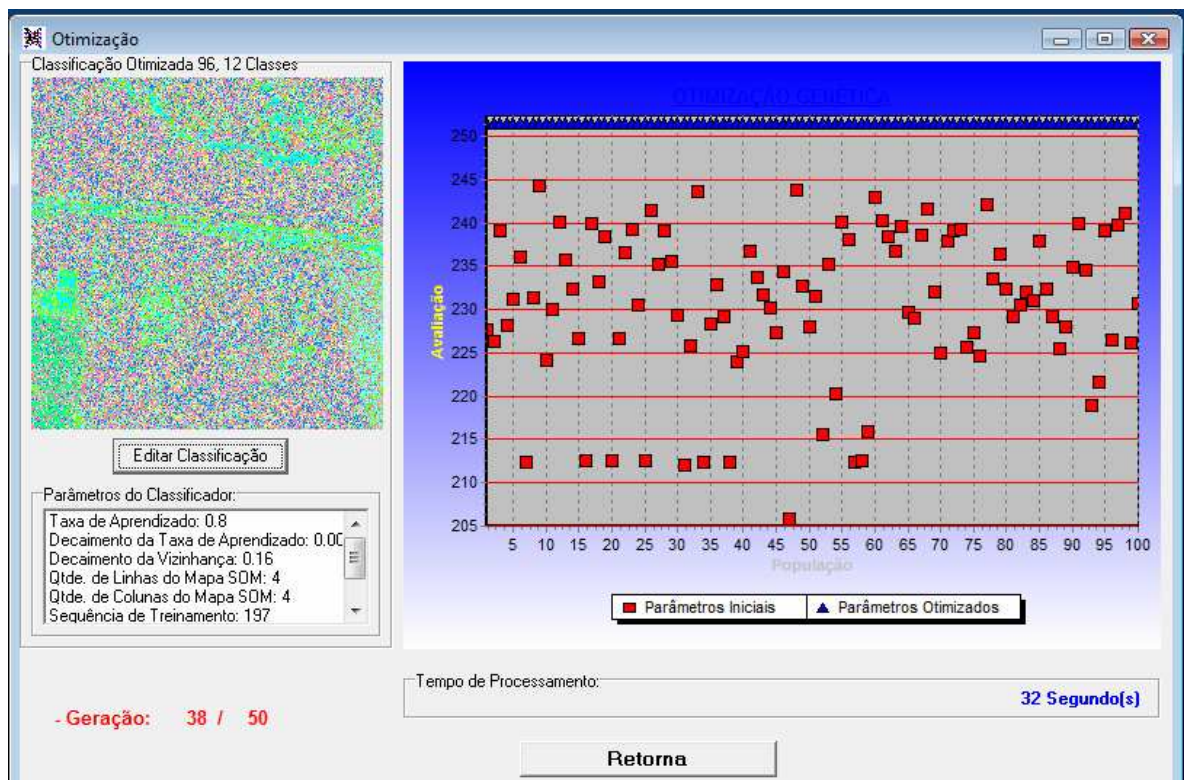


Figura 4-9 - Resultado do processo de classificação

Além disso, o usuário pode realizar ajuste das cores da quantidade de classes e salvar a classificação. A figura 4-10 demonstra essa possibilidade.

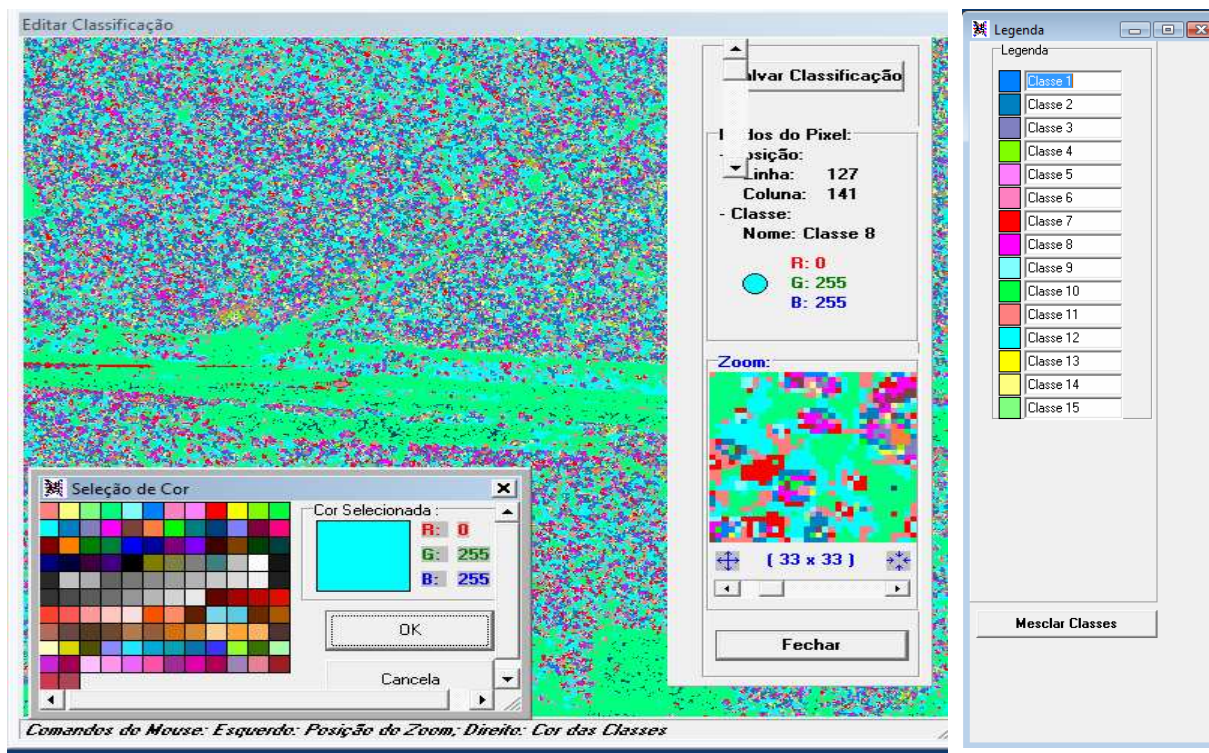


Figura 4-10 – Tela de edição da classificação.

Em virtude de ser um classificador não-supervisionado, no SGRNA não é possível inserir limites específicos de classes. As classes geradas são mescladas até chegar à quantidade desejada pelo usuário.

Outro ponto importante deste trabalho é a possibilidade de salvar a imagem diretamente na extensão lida pelo *software* ENVI. A partir daí, constrói-se a matriz de confusão e realiza-se o índice de Kappa.

4.2.4 Dados de Campo

Apesar da campanha feita para se conhecer a área de estudo, os dados de campo foram levantados em trabalhos anteriores.

Em 2008, a Secretaria de Desenvolvimento Urbano e Meio Ambiente (SEDUMA) realizou um trabalho denominado “Águas emendadas” que fez o mapeamento detalhado da flora, fauna, geologia, hidrologia, clima e solo dessa Estação. Além disso, foram feitas visitas e coletas de dados na área de estudo, onde se registraram áreas de agricultura de soja e áreas urbanas.

Com isso, este estudo foi direcionado para classificação de 3 tipos de cobertura da terra: cerrado, área urbana e área agriculturável.

A figura 4-11 exemplifica a primeira coleta de amostras de teste para serem utilizadas na classificação, como verdade de campo. Nela são representadas as regiões de interesse (ROI), extraídas em forma de polígonos, dos três tipos de cobertura da terra.




Figura 4-11 - Coleta da Região de Interesse (ROI)

A tabela 4-2 é o resultado da coleta das amostras das classes de referência.

Tabela 4-2 - Amostras das classes de referência

Classe	Descrição	Treinamento		Teste	
		Polígono	Pixels	Polígono	Pixels
Cerrado	Área de Cerrado - Parque Águas Emendadas	3	19.957	3	60.707
Agricultura	Área composta de lavouras de soja	3	16.475	3	31.350
Área Urbana	Urbano	4	7.859	4	23.628

4.2.5 Avaliação da exatidão da classificação

Após a conclusão da classificação, foi necessário avaliar a acurácia dos resultados obtidos. Isso permitiu mensurar o grau de confiança atribuído aos resultados e serviu para indicar se os objetivos da análise foram alcançados.

A acurácia foi determinada empiricamente, onde se selecionou uma amostra aleatória de pixel do mapa gerado (pós-classificação) e checkou-se com os dados conhecidos da área de estudo (verdade terrestre). Os pixels selecionados na amostra foram denominados pixels de teste. Desta seleção, verificou-se a porcentagem de pixel que foi rotulada corretamente pelo classificador, juntamente com as proporções de pixels classificados erroneamente, em todas as outras classes. Os resultados foram expressos em forma de tabela, denominada de matriz de erro ou matriz de confusão. Os valores listados na tabela representam o número de pixel de verdade terrestre, em cada caso, correta e incorretamente legendado pelo classificador SGRNA.

Para a geração das matrizes de confusão, a fim de torná-las em uma matriz quadrática, utilizou-se um programa na linguagem IDL, desenvolvido por Alcina Maria Nepomuceno. Este programa cruza informações, independentes do tamanho da matriz.

A escolha da amostra de pixels é um fator importante para avaliar a acurácia, entretanto, para se verificar a exatidão global das classificações e o índice de kappa, utilizou-se o segundo conjunto de amostras com as três classes de referência, descritas na tabela 4-2.

O passo final foi realizar um teste estatístico de hipóteses, cujo propósito foi verificar se os valores de kappa tinham importância significativa. Neste sentido, os valores das variâncias dos coeficientes kappa e os p-valores foram calculados em planilha do Excel.

4.2.6 Fluxograma da metodologia adotada no trabalho

Para facilitar a compreensão dos passos adotados na metodologia, apresenta-se o fluxograma (fig. 4-12) que resume as principais etapas desse processo.




Figura 4-12 - fluxograma da metodologia

5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados encontrados nos testes do sensor SAR aerotransportado do SIPAM à luz dos conceitos desenvolvidos nos capítulos anteriores. Para melhor entendimento, eles foram relacionados em três etapas: identificação dos tipos de filtro, análise do desempenho das Redes Neurais de Kohonen e classificação das imagens.

5.1 IDENTIFICAÇÃO DO TIPO DE FILTRO

Com o objetivo de eliminar ou minimizar o ruído Speckle das imagens SAR, procurou-se identificar em qual filtro adaptativo as imagens apresentaram os melhores resultados. Os resultados foram analisados de forma qualitativa e quantitativa.


5.1.1 Análise qualitativa:

A tabela 5-1 representa o resumo da análise qualitativa, cujo teor se baseia nos aspectos visuais das imagens filtradas, em relação à original.


Tabela 5-1 – Análise qualitativa das imagens, em relação ao tipo de filtro utilizado.

FILTRO	JANELA	CARACTERÍSTICA	RESULTADO
Frost	3x3	suavização das feições internas da imagem, gerando o efeito da imagem borrada.	redução das informações de contraste, de textura e relevo.
Lee	3x3	as feições internas ficaram mais homogêneas com a suavização.	efeito de imagem borrada
MAP gamma	3x3	fornece uma aparência mais binária à imagem	destaca as bordas


A figura 5-1 representa a visualização das imagens filtradas.



(A)



(B)



(C)




(D)


Figura 5-1 - Visualização da filtragem na imagem SAR. (A) Imagem original; (B) Filtro de Frost; (C) Filtro de Lee e (D) Filtro MAP gamma.

5.1.2 Análise quantitativa


Para testar a eficiência dos filtros mencionados anteriormente, o primeiro passo foi realizar a filtragem em todas as polarizações da banda L(HH, VH, VH e VV), conforme figura 5-2.




(a) Original em amplitude LHH




(b) Lee - LHH




(c) Frost Lhh




(d) MAPGA LHH




(e) Original em amplitude LHV



(f) Lee - LHV



(g) Frost LHV



(h) MAPGA LHV

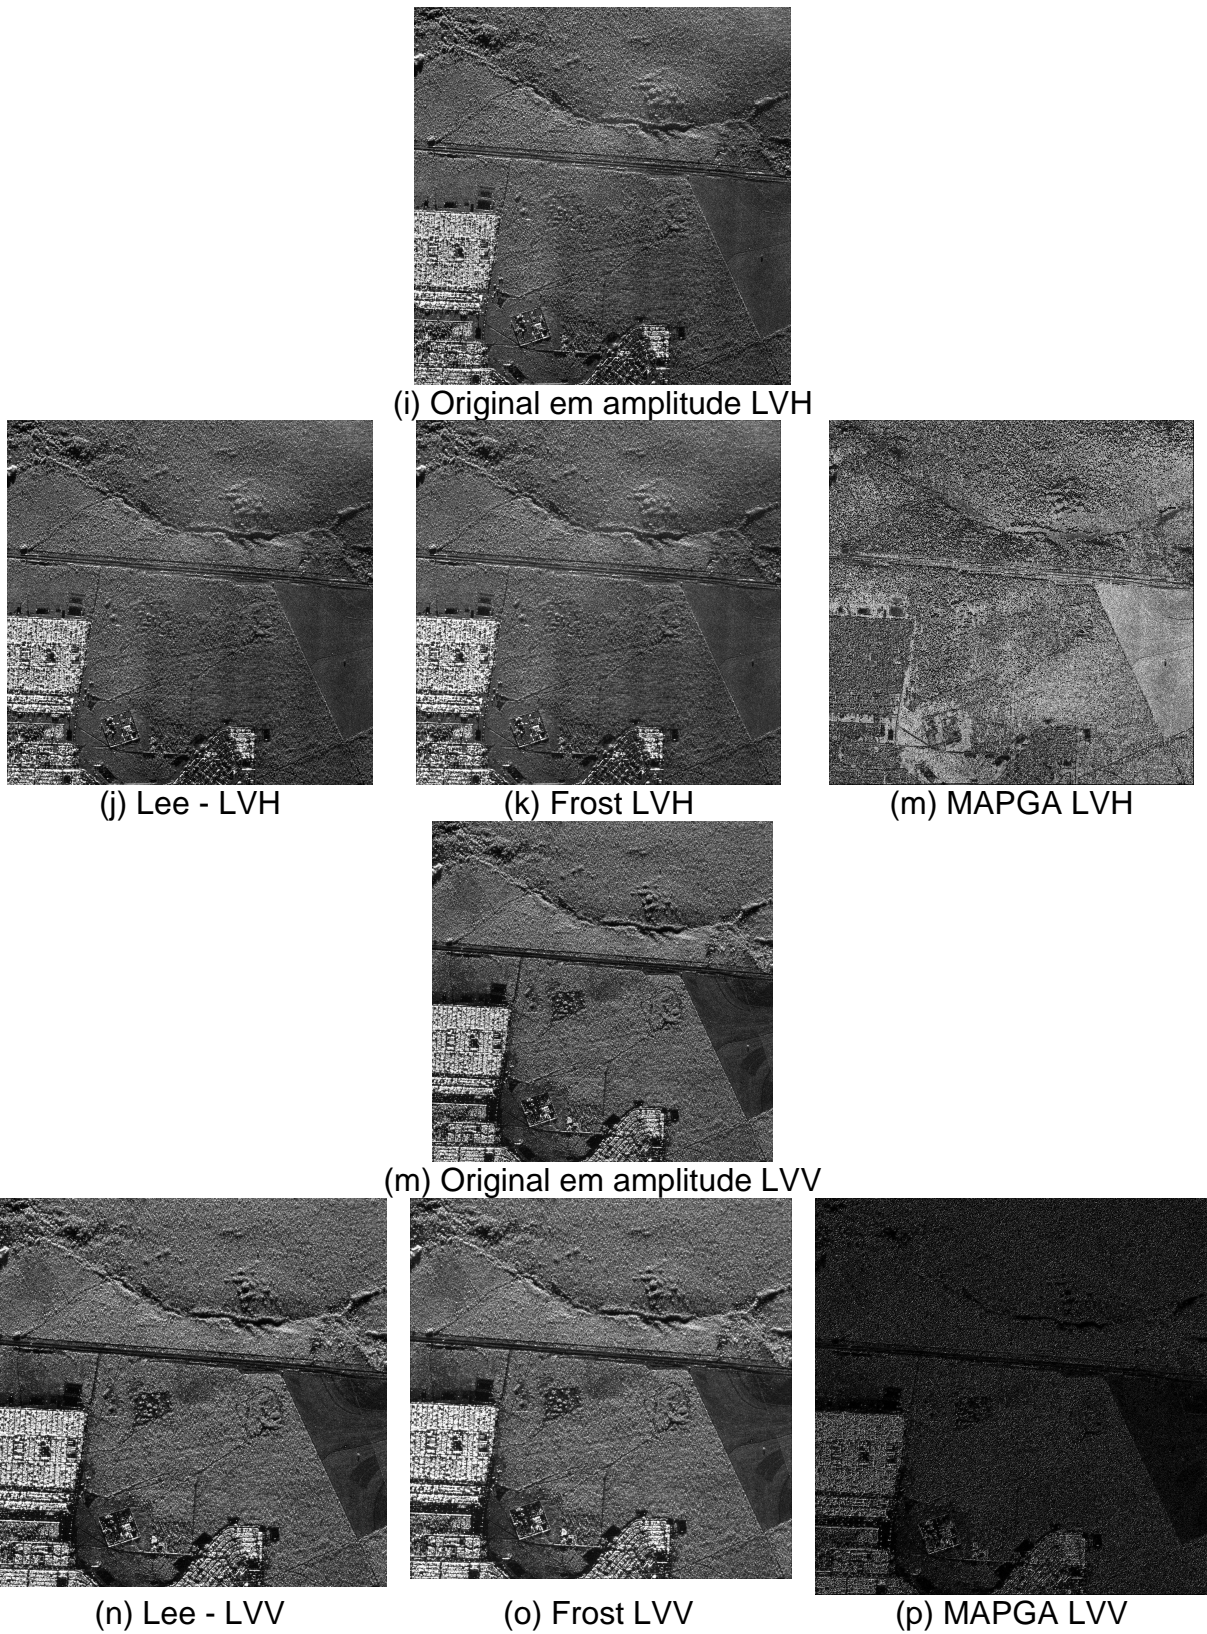


Figura 5-2 - Filtragem das imagens SAR

Após a filtragem inicial, procurou-se identificar em qual processamento ocorreu o menor MSE, a maior SNR e o β (beta) mais próximo à unidade, pois os

dois primeiros fatores são comuns na supressão de ruídos multiplicativos e o terceiro na identificação de bordas (Oliver & Quegan, 1998; e Mansourpour, 2006).

A tabela 5-2 indica os resultados encontrados de MSE, SNR e β (beta), utilizando a janela 3x3 em cada filtragem.

Tabela 5-2 – Resultados de MSE e SNR

Imagem	MSE	SNR	Beta
Lee hh (3x3)	2,4283	11,4159	0,7566
Lee hv (3x3)	4,0841	8,0494	0,7876
Lee vh (3x3)	1,5815	13,1714	0,7715
Lee vv (3x3)	3,9386	8,5157	0,7786
Frost hh (3x3)	7,5077	5,3564	0,3856
Frost hv (3x3)	17,0929	2,2456	0,4268
Frost vh (3x3)	8,2871	4,9489	0,4084
Frost vv (3x3)	11,8358	3,4842	0,4101
Map gamma adaptado hh (3x3)	4,7334	7,7320	0,3702
Map gamma adaptado hv (3x3)	7,9246	3,8875	0,4110
Map gamma adaptado vh (3x3)	4,7988	7,6679	0,3937
Map gamma adaptado vv (3x3)	7,0827	5,9002	0,3953

Através da tabela 5-2, percebe-se que os filtros de Lee e Map Gamma adaptado, expressaram os resultados significantes, com a redução do erro e aumento da SNR, na polarização VH. Também se observa que a filtragem com Lee indicou β ótimo efeito de preservação de bordas.

O próximo passo foi estender o tamanho da janela para 5x5 e 5x7 e verificar os resultados.

Tabela 5-3 – MSE para filtragem com janelas estendidas

Tipo_filtro	MSE		
	3x3	5x5	7x7
Lee hh	2,4283	4,1919	4,0114
Lee hv	4,0841	10,5780	14,3277
Lee vh	1,5815	5,2672	17,2635
Lee vv	3,9386	4,2379	6,9870
Frost hh	7,5077	12,0824	12,9313
Frost hv	17,0929	25,6479	37,6366
Frost vh	8,2871	13,3507	17,2635
Frost vv	11,8358	15,5699	19,6573
MAPGA hh	4,7334	7,4741	10,5088
MAPGA hv	7,9246	24,0120	33,3850
MAPGA vh	4,7988	8,9746	11,8480
MAPGA vv	7,0827	11,7815	14,3309

Onde o filtro Map Gamma Adaptado foi representado por (MAPGA).

Tabela 5-4 – SNR para filtragem com janelas estendidas

Tipo_filtro	SNR		
	3x3	5x5	7x7
Lee hh	11,4159	8,2832	8,4559
Lee hv	8,0494	3,6585	2,5390
Lee vh	13,1714	6,9470	2,7505
Lee vv	8,5157	7,9129	5,4979
Frost hh	5,3564	3,5433	3,4046
Frost hv	2,2456	1,8690	1,2283
Frost vh	4,9489	3,4374	2,7505
Frost vv	3,4842	2,9474	2,3934
MAPGA hh	7,7320	5,9641	4,7549
MAPGA hv	3,8875	2,2789	1,7253
MAPGA vh	7,6679	5,4447	4,5713
MAPGA vv	5,9002	2,9474	2,3934

Tabela 5-5 – Beta para filtragem com janelas estendidas

Tipo_filtro	Beta		
	3x3	5x5	7x7
Lee hh	0,7566	0,7671	0,7575
Lee hv	0,7876	0,8301	0,8638
Lee vh	0,7715	0,8153	0,2190
Lee vv	0,7786	0,8080	0,8357
Frost hh	0,3856	0,2287	0,2060
Frost hv	0,4268	0,2748	0,2687
Frost vh	0,4084	0,2361	0,2198
Frost vv	0,4101	0,2450	0,2318
MAPGA hh	0,3702	0,1764	0,1381
MAPGA hv	0,4110	0,2268	0,2051
MAPGA vh	0,3937	0,1919	0,1628
MAPGA vv	0,3953	0,1994	0,1736

Os resultados das tabelas 5-3, 5-4 e 5-5 indicaram que o aumento da janela de filtragem, independente do filtro e da polarização utilizada, causa aumento no MSE e diminuição da SNR. Também se observou que o β (beta) apresenta valores poucos alterados, à medida que se estende a janela de filtragem. Do ponto de vista do beta, a filtragem com Lee apresentou os melhores resultados.

Dessa forma, para o propósito deste trabalho, o ideal foi manipular imagens com filtradas com janelas 3x3, de acordo com as conclusões da análise do gráfico da figura 5-3.




Figura 5-3 - MSE e NSR

Além disso, e para complementar a análise, fez-se a comparação entre os gráficos para cada filtro e janela utilizados. No qual se comparou, principalmente, o filtro de Lee, em virtude dos resultados encontrados no estudo do MSE, SNR e beta.

Onde:

H_{org_k} = imagem original (vermelho);

H_{pro3x3_k} = imagem processada na janela 3x3 (azul);

H_{pro5x5_k} = imagem processada na janela 5x5 (verde);

H_{pro7x7_k} = imagem processada na janela 7x7 (róseo);

Eixo x = níveis de cinza; e

Eixo y = amplitude.




Figura 5-4 – Resultado da filtragem com Lee HV. Janelas (3x3), (5x5) e (7x7).




Figura 5-5 -- Resultado da filtragem com Lee VH. Janelas (3x3), (5x5) e (7x7).

As análises das polarizações cruzadas HV (fig 5-4) e VH (fig 5-5) indicam que há suavização do ruído Speckle em todas as janelas utilizadas na filtragem. A janela 3x3 (azul) é a que mais se aproxima do sinal original (vermelho), comprovando os valores encontrados para o MSE, SNR e beta.




Figura 5-6 - Resultado da filtragem com Lee HH. Janelas (3x3), (5x5) e (7x7).




Figura 5-7 - Resultado da filtragem com Lee VV. Janelas (3x3), (5x5) e (7x7).

A polarização direta (HH ou VV – fig. 5-7) também apresenta suavização do ruído Speckle (aspecto de ‘dente de serra’, no gráfico), onde todas as janelas de filtragem apresentam comportamento semelhante, com pouca variação de amplitude.




Figura 5-8 - Resultado da filtragem com Lee HV, frost HV) e Map gamma HV. Janela (3x3).

A análise final não estaria completa se os resultados das filtragens com as janelas 3x3 não fossem comparados com os encontrados em cada filtro proposto (fig. 5-8). A constatação dessa análise indica que o filtro que obteve o melhor resultado (mais próximo do sinal original), foi o filtro de Lee (cor azul no gráfico), sem descartar os demais filtros que, apesar de composição matemática diferente, também suavizam o ruído Speckle.

5.2 ANÁLISE DO DESEMPENHO DA REDE DE KOHONEN

A seguir, são apresentados os resultados dos testes feitos no classificador SGRNA, segundo os parâmetros de entrada da tabela 4-2 e com a perspectiva de estudar a Rede de Kohonen para classificação de imagens do radar de abertura sintética do SIPAM.

De maneira geral, os resultados foram significativos, a não ser os padrões de classificações processados para a composição colorida (HH, HV e VV), que geraram os piores resultados, com uma taxa de aprendizado variando entre 70% e 98% e apenas de dois a quatro padrões, por isso, excluídos do processo de apresentação de resultados.

A análise dos resultados da rede foi baseada no processamento das polarizações individuais (HH, HV, VH E VV). Teve foco em cinco aspectos principais: taxa de aprendizado; decaimento da taxa de vizinhança; quantidade de padrões; número de gerações; e erro de aprendizado. Analisou-se o processamento após filtragem com janelas 3x3, 5x5 e 7x7.

Tabela 5-6 - Resultado da rede SOM na imagem original.

Original	POLARIZAÇÃO			
	hh	hv	vh	vv
Taxa de aprendizado	0,869	0,899	0,996	0,99
Decaimento da vizinhança	0,17	0,0116	0,083	0,068
Nº Padrões	15	16	13	16
Nº Gerações	25	30	36	31

Tabela 5-7 - Resultado da rede SOM com o filtro de Lee.

Filtro	3x3			
Lee	hh	hv	vh	vv
Taxa de aprendizado	0,4	0,641	0,82	0,761
Decaimento da vizinhança	0,048	0,358	0,035	0,431
Nº Padrões	16	15	15	8
Nº Gerações	18	10	19	5
Erro de aprendizado	0,220	0,067	0,031	0,052

Filtro	5x5			
Lee	hh	hv	vh	vv
Taxa de aprendizado	0,504	0,589	0,53	0,927
Decaimento da vizinhança	0,521	0,454	0,259	0,178
Nº Padrões	3	10	12	14
Nº Gerações	1	5	6	6
Erro de aprendizado	0,133	0,096	0,217	0,004

Filtro	7x7			
Lee	hh	hv	vh	vv
Taxa de aprendizado	0,721	0,939	0,893	0,688
Decaimento da vizinhança	0,054	0,45	0,084	0,039
Nº Padrões	14	7	16	11
Nº Gerações	8	9	1	15
Erro de aprendizado	0,022	0,002	0,011	0,091

Os resultados gerados com a classificação, após a filtragem com Lee (tabela 5-7) demonstraram que a rede foi capaz de aprender, com baixa taxa de erro de aprendizagem. Ao se observar atentamente os dados da rede para a classificação com a janela 3x3, percebe-se que as polarizações cruzadas (HV e VH) apresentaram resultados significantes na taxa de aprendizado (0,641 e 0,82), respectivamente, com erro de aprendizagem aceitável. Este padrão se mantém para as demais janelas filtradas (5x5 e 7x7).

Outro fator importante é a quantidade de padrões que a rede produziu. Nestes termos, a pior classificação foi àquela realizada com a polarização HH, com apenas três padrões.

A comparação entre erros de aprendizado indica que a rede possui erros menores quando se utiliza a polarização cruzada.

Tabela 5-8 - Resultado da rede SOM com o filtro de Frost.

Filtro	3x3			
Frost	hh	hv	vh	vv
Taxa de aprendizado	0,629	0,575	0,707	0,985
Decaimento da vizinhança	0,063	0,41	0,309	0,189
Nº Padrões	16	12	11	9
Nº Gerações	12	2	1	6
Erro de aprendizado	0,058	0,105	0,084	0,000

Filtro	5x5			
Frost	hh	hv	vh	vv
Taxa de aprendizado	0,986	0,55	0,932	0,501
Decaimento da vizinhança	0,029	0,214	0,057	0,176
Nº Padrões	14	14	16	12
Nº Gerações	30	10	10	1
Erro de aprendizado	0,014	0,122	0,004	0,239

Filtro	7x7			
Frost	hh	hv	vh	vv
Taxa de aprendizado	0,883	0,49	0,75	0,923
Decaimento da vizinhança	0,292	0,203	0,218	0,091
Nº Padrões	16	10	14	15
Nº Gerações	6	5	11	8
Erro de aprendizado	0,000	0,167	0,061	0,004

A filtragem de Frost possibilitou resultados semelhantes de classificação (tabela 5-8). O erro se manteve estável, em torno de 0,1; os padrões são aceitáveis,

entre 9 e 16, porém com baixas indicações de gerações na filtragem com janela 3x3, com polarizações cruzadas. Quando isso acontece, o resultado final (imagem gerada) não atende à necessidade de extração de informação. Geralmente, o classificador apresenta os neurônios vencedores em uma única cor de saída, dificultando a análise.

Tabela 5-9 - Resultado da rede SOM com o filtro de MAP gamma.

Filtro	3x3			
MAP GAMMA Adaptado	hh	hv	vh	vv
Taxa de aprendizado	0,907	0,663	0,644	0,977
Decaimento da vizinhança	0,068	0,285	0,38	0,048
Nº Padrões	8	12	7	13
Nº Gerações	11	4	5	7
Erro de aprendizado	0,001	0,056	0,124	0,000

Filtro	5x5			
MAP GAMMA Adaptado	hh	hv	vh	vv
Taxa de aprendizado	0,596	0,677	0,58	0,993
Decaimento da vizinhança	0,096	0,285	0,147	0,415
Nº Padrões	12	15	16	11
Nº Gerações	13	4	24	34
Erro de aprendizado	0,075	0,049	0,173	0,000

Filtro	7x7			
MAP GAMMA Adaptado	hh	hv	vh	vv
Taxa de aprendizado	0,985	0,775	0,897	0,623
Decaimento da vizinhança	0,165	0,286	0,178	0,101
Nº Padrões	6	12	6	16
Nº Gerações	1	4	7	2
Erro de aprendizado	0,013	0,015	0,010	0,135

Os resultados com o filtro MAP Gamma Adaptado são semelhantes aos encontrados na classificação com Lee, porém com os menores erros de aprendizado na filtragem 3x3 (tabela 5-9).

A quantidade de padrões foi semelhante para cada processamento individual, entre 9 e 16, mesmo sem a filtragem da imagem.

Finalmente, percebeu-se que a cada nova otimização com a mesma imagem de entrada, o número de gerações variava, apesar de os parâmetros iniciais da rede não serem alterados.

5.3 CLASSIFICAÇÃO DAS IMAGENS

O conjunto de exatidão global e índice de Kappa foram calculados para 3 classes.

As tabelas 5-10, 5-11 e 5-12 apresentam os resultados da pós-classificação das imagens. Neles evidenciam-se os valores de acurácia global das matrizes de confusão, o valor de kappa e a qualidade do mapa temático.

Além disso, fez-se o teste estatístico, considerando as seguintes hipóteses:

$$H_0 = k = 0$$

$$H_1 = k > 0$$

Onde se calculou o z com a seguinte fórmula:

$$z = \frac{\hat{k}}{\sqrt{\text{Var}(\hat{k})}} \quad (5-1)$$

Tabela 5-10 - Resultado da classificação, após filtragem com Lee.

IMAGEM FILTRADA COM LEE	POLARIZAÇÃO	ACURÁCIA GLOBAL	KAPPA (k)	VARIÂNCIA DE k	Z	QUALIDADE DO MAPA TEMÁTICO
3x3	HH	66,70%	0,489	0,003807	8,904	boa
	HV	79,00%	0,678	0,001995	8,547	muito boa
	VH	73,30%	0,593	0,00481	15,180	boa
	VV	60,00%	0,391	0,002523	7,793	razoável
5x5	HH	73,60%	0,571	0,004108		boa
	HV	74,90%	0,6	0,002431	12,174	muito boa
	VH	55,80%	0,28	0,00317	4,975	ruim
	VV	69,70%	0,53	0,003665	8,751	boa
7x7	HH	74,60%	0,614	0,001747	14,689	muito boa
	HV	61,80%	0,41	0,003922	6,546	boa
	VH	83,90%	0,748	0,001629	18,533	muito boa
	VV	59,80%	0,393	0,004232	6,048	razoável

Tabela 5-11 - Resultado da classificação, após filtragem com Front

IMAGEM FILTRADA COM FROST	POLARIZAÇÃO	ACURÁCIA GLOBAL	KAPPA	VARIÂNCIA DE k	Z	QUALIDADE DO MAPA TEMÁTICO
3x3	HH	82,40%	0,612	0,004291	9,34	muito boa
	HV	79,50%	0,684	0,00207	15,03	muito boa
	VH	71,70%	0,563	0,002095	12,30	boa
	VV	50,00%	0,207	0,002356	4,27	razoável
5x5	HH	88,80%	0,8	0,001403	21,36	muito boa
	HV	63,10%	0,428	0,003443	7,29	boa
	VH	66,70%	0,46	0,002773	8,73	boa
	VV	59,00%	0,334	0,004801	4,81	razoável
7x7	HH	84,10%	0,598	0,005241	8,27	boa
	HV	75,20%	0,587	0,002175	12,59	boa
	VH	81,00%	0,679	0,002406	13,84	muito boa
	VV	77,40%	0,604	0,014571	5,00	muito boa

Tabela 5-12 – Resultado da classificação, após filtragem com MAPGAD.

IMAGEM FILTRADA COM MAPGAD	POLARIZAÇÃO	ACURÁCIA GLOBAL	KAPPA	VARIÂNCIA DE k	Z	QUALIDADE DO MAPA TEMÁTICO
3x3	HH	65,90%	0,478	0,002683	9,22	boa
	HV	63,00%	0,442	0,003663	7,30	boa
	VH	82,80%	0,733	0,001607	18,29	muito boa
	VV	72,60%	0,564	0,002518	11,24	boa
5x5	HH	81,50%	0,699	0,001703	16,93	muito boa
	HV	64,50%	0,466	0,002824	8,77	boa
	VH	46,70%	0,208	0,002637	4,04	razoável
	VV	81,50%	0,709	0,001743	16,98	muito boa
7x7	HH	81,00%	0,692	0,00177	16,44	muito boa
	HV	42,40%	0,174	0,002223	3,70	ruim
	VH	52,20%	0,274	0,00835	3,00	razoável
	VV	75,90%	0,623	0,002758	11,86	muito boa

A conclusão inicial do teste estatístico indicou H_0 deve ser rejeitada, com 5% de significância, ou seja, há concordância entre as classificações e as amostras de referência coletadas em cada polarização.

A segunda conclusão diz respeito à acurácia global dos testes. Em todos os casos analisados, os valores oscilaram entre 60% e 80%, sendo que as médias de acurácia nas classificações com Lee e MAPGAD foram semelhantes (69,43% e 67,50%, respectivamente).

Finalmente, no que diz respeito à qualidade dos mapas temáticos, não houve classificação considerada ruim e, por isso, qualquer produto do SGRNA, dentro dos parâmetros testados, poderia ser utilizado na geração do produto final de classificação.

Em virtude dos resultados encontrados anteriormente, nos quais as filtragens com janela 3x3, com polarizações cruzadas (HV ou VH), indicaram mais eficiência para classificação, fez-se o teste estatístico valor p.

Considerando:

$$H_{01}: \kappa_1 - \kappa_2 = 0$$

$$H_{11}: \kappa_1 - \kappa_2 > 0$$

Onde,

K_1 = Kappa da classificação1

K_2 = Kappa da classificação2

Com a seguinte formulação:

$$z_1 = \frac{\hat{\kappa}_1 - \hat{\kappa}_2}{\sqrt{\text{Var}(\hat{\kappa}_1) + \text{Var}(\hat{\kappa}_2)}} \quad (5-2)$$

Para embasamento das respostas dos testes, considerou-se o seguinte:

Se, P-valor < 0,01: há elevada significância estatística; evidência muito forte contra a hipótese nula;

P-valor entre 0,01 e 0,05: estatisticamente significativa; evidência adequada contra a hipótese nula; e

P-valor > 0,05: evidência insuficiente contra a hipótese nula

Assim sendo, buscou-se conhecer se a concordância nas imagens classificadas, após filtragem com Lee (K_1) e MAPGAD (K_2):

$$H_{01}: \kappa_1 - \kappa_2 = 0$$

$$H_{11}: \kappa_1 - \kappa_2 > 0$$

$$\alpha = 0,05$$

Tabela 5-13 – Concordância entre classificações, após filtragem com Lee e MAPGAD e na polarização HV.


IMAGEM CLASSIFICADA	POLARIZAÇÃO	KAPPA	VARIANCIA DE KAPPA	z	p-value
Lee 3x3 (k1)	HV	0,678	0,001995	-0.91	0,181411
MAPGAD 3x3 (K2)	HV	0,442	0,003663		

Tabela 5-14 – Concordância entre classificações, após filtragem com Lee e MAPGAD e na polarização VH.

IMAGEM CLASSIFICADA	POLARIZAÇÃO	KAPPA	VARIANCIA DE KAPPA	z	p-value
Lee 3x3 (k1)	VH	0,593	0,00481	1.64	0,949497
MAPGAD 3x3 (K2)	VH	0,733	0,001607		

Para o caso das polarizações cruzadas (HV e VH), após a filtragem com Lee e MAPAD com janela 3x3, há evidência insuficiente para rejeitar a hipótese nula, assim sendo, aceita-se que há concordância entre as imagens classificadas com as referências de solo, dentro dos parâmetros testados.


As figuras 5-9 e 5-10 são os resultados da classificação da banda L, na polarização HV, após filtragem com o filtro MAPGAD e com Lee, com a janela 3x3.



Legenda:

Yellow	Cerrado
Red	Agricultura
Pink	Área urbana
Blue	Outros

Figura 5-9 - Classificação após filtragem com MAPGAD.



Legenda:

	Cerrado
	Agricultura
	Área urbana
	Outros

Figura 5-10 – Classificação após filtragem com Lee HV, com a janela 3x3.

As figuras indicam que as classificações são semelhantes, apesar de não possuírem 100% de padrões iguais, mas representam os alvos estudados.

Convém ressaltar que os testes foram da maneira empregada nos trabalhos diários de análises de Geoprocessamento da FAB, ou seja, primeiro se avalia se é possível inferir algumas características de um alvo, a partir da imagem original, sem nenhum tratamento de ruído; depois, com as técnicas de processamento digital de imagens, procura-se encontrar qual o tipo de filtro e em qual polarização o alvo é apresentado com maior destaque, dentro dos preceitos de forma, cor, sombra e tonalidade (interpretação visual), posteriormente, aplica-se um classificador de imagens para facilitar a manipulação da imagem pelo intérprete. Com isso, reduz-se a incerteza sobre as características físicas de um alvo.

6 CONSIDERAÇÕES FINAIS

Este trabalho abordou o uso de redes neurais artificiais para classificação de imagens do Radar de Abertura Sintética do SIPAM. Foram apresentadas em detalhes as características do sensor multipolarimétrico brasileiro, o ruído Speckle, as formas de filtragem, os fundamentos da polarização, as principais redes neurais artificiais, a classificação de imagens e o índice de Kappa.

Utilizou-se classificação não-supervisionada, com síntese genética e a rede de Kohonen para processamento dos dados.

Todo o trabalho foi planejado e realizado para incentivar o uso de tecnologias e recursos nacionais. Nesse sentido, a Força Aérea cedeu imagens da banda L do SAR, nas quatro polarizações, e utilizou-se o programa SGRNA como base para realizar a classificação.

De acordo com a metodologia utilizada e os resultados obtidos nesta pesquisa, evidenciou-se que o processo de filtragem para redução do ruído speckle melhorou a classificação das imagens.

A classificação permitiu a discriminação dos seguintes grupos de cobertura da terra: Cerrado, área de agricultura e área urbana. Entretanto, são necessários mais testes para esgotar todas as possibilidades do classificador.

Como continuação desta investigação, recomenda-se a utilização e avaliação de outros produtos de sensores remotos que estejam disponíveis ao alcance da comunidade científica brasileira, tais como imagens do CBERS e da câmara ADS-80, recentemente adquirida pela FAB. Também se sugere que o SGRNA se torne um software livre.

7 REFERÊNCIAS BIBLIOGRÁFICAS


- ANDRADE N. S. O & SANTA ROSA, A. N. **Características do sensor SAR multipolarimétrico aerotransportado Brasileiro**. In: Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, p. 7027-2030, 2007a.
- ANDRADE N. S. O & SANTA ROSA, A. N. **Produtos do sensor SAR multipolarimétrico aerotransportado Brasileiro**. In: Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, p. 7035-2042, 2007b.
- ANDRADE N. S. O; SANTA ROSA, A. N.; e FARIA, P. C. C. **Fundamentos da polarimetria SAR**. In: Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, p. 7035-2042, 2007c.
- BRAGA, A. P.; CARVALHO, A. P.L.F.; e LUDEMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. 2ed. Rio de Janeiro: LTC. p. 87-111, 2007.
- BRASIL. **Política de Sensoriamento Remoto da Aeronáutica**. DCA 510-1. 1999.
- CABRAL JÚNIOR, E. F. **Redes Neurais Artificiais: um curso teórico e prático para engenheiros e cientistas**. Grupo de comunicação homem máquina da Escola politécnica da USP. São Paulo. p. 43-63, 1999.
- CURLANDER, J. C. & McDONOUGH, R.N. **Sythetic Aperture Radar. Systems and Signal processing**. New York, 1991.
- FONSECA, F. O. **Águas emendadas**. Distrito Federal. Secretaria de Desenvolvimento Urbano e Meio Ambiente. Brasília: SEDUMA. 542p, 2008.
- GONÇALVES, N. V. **Classificação automática de informações geomorfológicas utilizando redes neurais**. Dissertação de mestrado. Brasília. UnB. 103p, 1996.
- GOJ, WALTER W. **Syntetich aperture radar and eletronic warfare**. p. 1-33, 1993.
- HAYKIN, S. **Redes Neurais: princípios e práticas**. Trad. Paulo Martins Engel. -2º Ed. Porto Alegre: Bookman.p. 27-143, 2001.
- HOLLAND, J. H. **Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control and artificial intelligence**. 1st MIT Press ed. 194p, 1992.
- KINGSLEY, S. P. & QUEGAN, S. **Understanding radar system**. England. p.1-23, 1992.
- KOHONEN, T. & MÄKISARA, K. **The Self-organizing Feature Maps**. Revista Physica Scripta. Vol. 39, 168-172, 1989.
- KOHONEN, T. **The Self-organizing Map**. proceedings of the IEEE, vol. 78, no. 9, September, 1990.
- KRAMER J. C. M., LACRUZ M. S. P., KEIL M., SANTOS J. R., ARAÚJO L. S. **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, 2001.
- INMET. **Instituto Nacional de Meteorologia**. Disponível em <http://www.inmet.gov.br/>. Acesso em abril de 2010.
- MAHAFZA, BASSEM R. **Radar system analysis and design using Matlab**, p 3 – 73, 2000.
- MATHER, PAUL M. **Computer processing of Remotely - Sensed Images: an introduction**. Second ed. England, 319 pp 147-165, 1999.
- MATHER, PAUL M. **Computer processing of Remotely - Sensed Images: an introduction**. 3º ed. England, 319 pp 1-66, 2004.
- MANSOURPOUR, M.; RAJABI, M.A; e BLAIS, J.A.R. **Effects and performance of speckle noise reduction filters on active radar and sar images**, 2006.
- MORAES NOVO, E. M. L. **Sensoriamento Remoto: princípios e aplicações**. 3 ed. São Paulo: Blucher. , pp.: 205-292, 2008.

- NEPOMUCENO, A. M.; VALERIANO, D. M.; FREITAS, C. C.; SANTA ROSA, A. N. C.; SILVA, N. C.; SANTOS, J. R.; DUTRA, L. V. **Classificação de dados de radar para mapeamento de cobertura da terra na região de Santarém, Pará.** In.: Anais XI SBSR, Belo Horizonte, p 2249-2256, . 2003a.
- NEPOMUCENO, A. M. **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, 2003b.
- OLIVER, C. & QUEGAN, S. **Understanding Synthetic Aperture Radar Images.** London. p. 413 – 450, 1998.
- PACHECO, M. A. C. **Algoritmos Genéticos: princípios e aplicações.** Laboratório de Inteligência Computacional Aplicada. PUC – Rio de Janeiro. 9p, 1999.
- PINHEIRO G. G. C. **Análise dos dados digitais de imagem de radar (satélite JERS-1, Banda L) para estudos de vegetação, solos e geologia na região do cerrado.** Dissertação de Mestrado. Universidade de Brasília, 102 p, 1992.
- QUEIROZ, ROSSANA B.; SEVERINO, PRISCILA A. DA R.; RODRIGUES, ANTONIO G.; e 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 Inteligência Artificial, 2004.
- REATTO A.; CORREIA J. R.; e SPERA S. T.. **Solos do Bioma Cerrado: aspectos pedológicos.** In: Sano S. M. & Almeida S. P. 1998. Cerrado ambiente e flora. EMBRAPA-CPAC, Planaltina, GO. p.: 89-152, 1998.
- RENCZ, N. ANDREW. **Remote sensing for the earth sciences: manual of remote sensing.** 3º ed, vol. 3, Geological Survey of Canadá, p. 613-646, 1999.
- ROJAS, E. H. M. **Síntese genética de redes neurais artificiais ART2 na classificação de imagens ASTER para mapeamento de uso e cobertura da terra na região norte do mato grosso.** . Dissertação de mestrado. São José dos Campos. INPE. 126p, 2005.
- SANT'ANNA S. J. S.; FERNANDES D.; e LACAVA J. C. S.. **Análise comparativa do desempenho de filtros redutores de "speckle" em imagens sar.** In: IX SBT, Simp. Tel. Fortaleza, 2001.
- SANTA ROSA A. N. C. & MENESES P. R. **Performance of MAP filters to reduce speckle in RADARSAT images.** In: GLOBESAR. Buenos Aires. Proceedings. CONAE, v. 1, p. 876-880, 1999.
- SILVA, N. C. **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, 2003.
- 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. & ELACHI, CHARLES. **Radar polarimetry for geoscience applications.** Published 1990 by Artech House in Norwood, MA, 1990.
- VERGARA, S.YLVIA CONSTANT. **Projetos e relatórios de pesquisa em administração.** -5. ed. – São Paulo: Atlas, 2004.
- ZOTTICH, D. G.; PINHEIRO, J. M.; FREITAS, M. S.; e MEDEIROS, V. A. F. **Aspectos fisiográficos, bióticos e antrópicos da bacia hidrográfica do Rio Maranhão,** 2007. 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.


APÊNDICE A – FILTRAGEM DE DADOS

Histogramas resultantes da filtragem de dados com MAP Gamma adaptado (3x3), (5x5) e (7x7)

a) HH




b) HV




APÊNDICE A – FILTRAGEM DE DADOS (Continuação)

c) VH




d) VV




APÊNDICE A – FILTRAGEM DE DADOS (Continuação)

Histogramas resultantes da filtragem de dados com Frost (3x3), (5x5) e (7x7)

a) HH




b) HV




APÊNDICE A – FILTRAGEM DE DADOS (Continuação)

Histogramas resultantes da filtragem de dados com Frost (3x3), (5x5) e (7x7)

c) VH



d) VV



APÊNDICE B – CÓDIGO UTILIZADO NO MATCHAD PARA COMPOR O HISTOGRAMA DA FILTRAGEM DE DADOS

Imgor: = READ_IMAGE('imagem original')

Imgproc_3x3: = READ_IMAGE('imagem processada 3x3')

Imgproc_5x5: = READ_IMAGE('imagem processada 5x5')

Imgproc_7x7: = READ_IMAGE('imagem processada 7x7')


Horg:=imhist(imgor, 256)

Horg:=imhist(imgproc3x3, 256)

Horg:=imhist(imgproc5x5, 256)

Horg:=imhist(imgproc5x5, 256)

K:= 0...rows(imgorg)-1



APÊNDICE C – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O MSE

```
function MSE=mse(img_filt,img_org)

%carregar imagem 1 gerando matriz real M1
M1=imread(img_filt);

%carregar imagem 2 gerando matriz real M2
M2=imread(img_org);

%calcular MSE
M=M1-M2;
K=length(M)^2;
MSE=1/K*sum(sum(M));

end
```

APÊNDICE D – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O SNR

```
function snr=SNRimagem(img_filt,img_org)

%carregar imagem 1 gerando matriz real M1
M1=imread(img_filt);

%carregar imagem 2 gerando matriz real M2
M2=imread(img_org);

%calcular MSE
K=length(M1)^2;
FATOR1=sum(sum(M2.^2));
FATOR2=sum(sum((M1-M2).^2));
snr=10*log10(FATOR1/FATOR2);

end
```

APÊNDICE E – CÓDIGO UTILIZADO NO MATLAB PARA CALCULAR O BETA

```
function valor_beta=beta(imgorg,imgproc,TAMJANELA)

%ler imagens
IMGRDO=imread(imgorg);
IMGPROC=imread(imgproc);

%aplicar filtro laplaciano
alpha=0;
filt_lplcyn=-fspecial('laplacian',alpha);%cria filtro laplaciano pela
matriz (8)

LP_IMGRDO=imfilter(IMGRDO,filt_lplcyn);%filtra a img. original
LP_IMGPROC=imfilter(IMGPROC,filt_lplcyn);%filtra a imagem processada

%calcular beta
filt_media=fspecial('average',TAMJANELA);%cria filtro média
MEDIALP_IMGRDO=imfilter(LP_IMGRDO,filt_media);%filtra a img.
MEDIALP_IMGPROC=imfilter(LP_IMGPROC,filt_media);%filtra a img.

NUM=gama(LP_IMGRDO-LP_IMGPROC,LP_IMGPROC-MEDIALP_IMGPROC);
DEN=sqrt( gama(LP_IMGRDO-MEDIALP_IMGRDO,LP_IMGRDO-MEDIALP_IMGRDO)*...
    gama(LP_IMGRDO-LP_IMGPROC,LP_IMGPROC-MEDIALP_IMGPROC) );

valor_beta=NUM/DEN;

%sair
end
```

APÊNDICE F – RESULTADOS DA REDE DE KOHONEN

Tabela resultante da classificação com o filtro de Lee

Filtro	3x3				
Lee	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,4	0,641	0,82	0,761	0,954
Decaimento da taxa de aprendizado	0,1	0,46	0,27	0,22	0,5
Decaimento da vizinhança	0,048	0,358	0,035	0,431	0,357
Quantidade de linhas do Mapa SOM	4	4	4	3	3
quantidade de colunas do Mapa SOM	4	4	4	3	4
Sequencia de treinamento	229	93	126	100	25
Avaliação	254,98	255	254,99	254,98	255
Nº Padrões	16	15	15	8	3
Nº Gerações	18	10	19	5	2

Filtro	5x5				
Lee	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,504	0,589	0,53	0,927	1
Decaimento da taxa de aprendizado	0,01	0,01	0,001	0,04	0,15
Decaimento da vizinhança	0,401	0,454	0,259	0,178	0,421
Quantidade de linhas do Mapa SOM	3	3	4	4	1
quantidade de colunas do Mapa SOM	3	4	3	4	2
Sequencia de treinamento	182	152	214	223	58
Avaliação	254,97	255	254,98	254,99	254,99
Nº Padrões	3	10	12	14	2
Nº Gerações	1	5	6	6	2

Filtro	7x7				
Lee	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,721	0,939	0,893	0,688	0,972
Decaimento da taxa de aprendizado	0,01	0,34	0,21	0,01	0,16
Decaimento da vizinhança	0,054	0,45	0,084	0,039	0,416
Quantidade de linhas do Mapa SOM	4	3	4	4	3
quantidade de colunas do Mapa SOM	2	3	4	4	1
Sequencia de treinamento	45	58	79	55	167
Avaliação	254,98	58	24,99	254,99	255
Nº Padrões	14	7	16	11	3
Nº Gerações	8	9	1	15	1

APÊNDICE F – RESULTADOS DA REDE DE KOHONEN (continuação)

Tabela resultante da classificação com o filtro de Frost

Filtro	3x3				
Frost	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,629	0,575	0,707	0,985	0,993
Decaimento da taxa de aprendizado	0,31	0,46	0,02	0,16	0,12
Decaimento da vizinhança	0,063	0,41	0,309	0,189	0,076
Quantidade de linhas do Mapa SOM	4	4	3	3	2
quantidade de colunas do Mapa SOM	4	4	4	3	2
Sequencia de treinamento	247	140	127	128	201
Avaliação	254,98	255	254,99	254,99	255
Nº Padrões	16	12	11	9	1
Nº Gerações	12	2	1	6	4

Filtro	5x5				
Frost	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,986	0,55	0,932	0,501	0,978
Decaimento da taxa de aprendizado	0,02	0,001	0,12	0,08	0,012
Decaimento da vizinhança	0,029	0,214	0,057	0,176	0,162
Quantidade de linhas do Mapa SOM	4	4	4	4	1
quantidade de colunas do Mapa SOM	4	4	4	4	2
Sequencia de treinamento	233	7	170	159	183
Avaliação	254,99	255	254,99	254,99	255
Nº Padrões	14	14	16	12	1
Nº Gerações	30	10	10	1	5

Filtro	7x7				
Frost	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,883	0,49	0,75	0,923	0,954
Decaimento da taxa de aprendizado	0,03	0,33	0,09	0,36	0,11
Decaimento da vizinhança	0,292	0,203	0,218	0,091	0,367
Quantidade de linhas do Mapa SOM	4	3	4	4	3
quantidade de colunas do Mapa SOM	4	4	4	4	1
Sequencia de treinamento	114	0	140	111	112
Avaliação	254,98	255	254,98	254,99	
Nº Padrões	16	10	14	15	1
Nº Gerações	6	5	11	8	8

APÊNDICE F – RESULTADOS DA REDE DE KOHONEN (continuação)

Tabela resultante da classificação com o filtro de MAP gamma Adaptado

Filtro	3x3				
MAP GAMMA Adaptado	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,907	0,663	0,644	0,977	0,98
Decaimento da taxa de aprendizado	0,28	0,001	0,03	0,06	0,11
Decaimento da vizinhança	0,068	0,285	0,38	0,048	0,027
Quantidade de linhas do Mapa SOM	3	4	2	4	1
quantidade de colunas do Mapa SOM	4	4	4	4	3
Sequencia de treinamento	176	16	161	2	192
Avaliação	254,98	255	254,97	245,99	255
Nº Padrões	8	12	7	13	1
Nº Gerações	11	4	5	7	7

Filtro	5x5				
MAP GAMMA Adaptado	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,596	0,677	0,58	0,993	0,954
Decaimento da taxa de aprendizado	0,03	0,21	0,02	0,11	0,11
Decaimento da vizinhança	0,096	0,285	0,147	0,415	0,367
Quantidade de linhas do Mapa SOM	4	4	4	4	3
quantidade de colunas do Mapa SOM	4	4	4	4	1
Sequencia de treinamento	233	33	211	11	112
Avaliação	254,97	255	254,99	254,99	255
Nº Padrões	12	15	16	11	1
Nº Gerações	13	4	24	34	2

Filtro	7x7				
MAP GAMMA Adaptado	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,985	0,775	0,897	0,623	0,986
Decaimento da taxa de aprendizado	0,05	0,14	0,19	0,01	0,06
Decaimento da vizinhança	0,165	0,286	0,178	0,101	0,182
Quantidade de linhas do Mapa SOM	2	3	2	4	4
quantidade de colunas do Mapa SOM	3	4	4	4	1
Sequencia de treinamento	23	123	16	206	25
Avaliação	254,98	255	254,99	254,99	255
Nº Padrões	6	12	6	16	2
Nº Gerações	1	4	7	2	26

APÊNDICE F – RESULTADOS DA REDE DE KOHONEN (continuação)

Tabela resultante da classificação com a imagem original

Original	POLARIZAÇÃO				
	hh	hv	vh	vv	hh hv vv
Taxa de aprendizado	0,869	0,899	0,996	0,99	1
Decaimento da taxa de aprendizado	0,001	0,001	0,001	0,001	0,14
Decaimento da vizinhança	0,17	0,0116	0,083	0,068	0,194
Quantidade de linhas do Mapa SOM	4	4	4	4	3
quantidade de colunas do Mapa SOM	4	4	4	4	3
Sequencia de treinamento	104	143	99	160	101
Avaliação	252,19	251,26	252,03	251,74	255
Nº Padrões	15	16	13	16	1
Nº Gerações	25	30	36	31	7

APÊNDICE G – MATRIZES DE CUNFUSÃO

Filtragem com Frost (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

a) LHH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	19,79	9	1
Área urbana	6	95,15	3
Agricultura	4	3	8,2756

b) LHH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	82	5	8
Área urbana	1	6	6
Agricultura	0	3	95

c) LHH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	13,47	7	4
Área urbana	1	1	1
Agricultura	3	2	80

d) LHV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	69	9	5
Área urbana	4	26	13
Agricultura	0	5	45

e) LHV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	21	3	6
Área urbana	9	52	6
Agricultura	17	11	16

f) LHV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	24	15	13
Área urbana	2	98	1
Agricultura	6	14	33

APÊNDICE G – MATRIZES DE CUNFUSÃO (continuação)

Filtragem com Frost (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

g) LVH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	29	14	10
Área urbana	5	73	18
Agricultura	11	5	58

h) LVH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	30	19	8
Área urbana	8	11	13
Agricultura	3	6	73

i) LVH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	72	8	16
Área urbana	0	16	0
Agricultura	10	1	61

j) LVV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	20	16	5
Área urbana	3	8	63
Agricultura	3	5	67

k) LVV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	38	23	7
Área urbana	3	15	2
Agricultura	0	6	6

l) LVV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	16	0	1
Área urbana	4	5	2
Agricultura	0	0	3

APÊNDICE G – MATRIZES DE CUNFUSÃO (continuação)

Filtragem com Lee (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

a) LHH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	29	12	4
Área urbana	0	4	3
Agricultura	0	15	35

b) LHH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	15	5	10
Área urbana	5	50	5
Agricultura	3	1	16

c) LHH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	67	20	1
Área urbana	10	72	0
Agricultura	5	25	40

d) LHV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	16	8	4
Área urbana	1	31	2
Agricultura	2	7	19

e) LHV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	28	10	12
Área urbana	3	76	5
Agricultura	4	12	33

f) LHV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	39	4	33
Área urbana	0	12	2
Agricultura	0	3	17

APÊNDICE G – MATRIZES DE CUNFUSÃO (continuação)

Filtragem com Lee (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

g) LVH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	27	14	7
Área urbana	3	63	2
Agricultura	6	7	57

h) LVH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	21	9	20
Área urbana	2	16	32
Agricultura	5	12	64

i) LVH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	46	4	8
Área urbana	7	38	5
Agricultura	1	7	83

j) LVV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	24	4	7
Área urbana	36	12	2
Agricultura	12	5	63

k) LVV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	9	6	2
Área urbana	0	44	5
Agricultura	20	3	30

l) LVV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	23	5	9
Área urbana	20	12	5
Agricultura	5	3	35

APÊNDICE G – MATRIZES DE CUNFUSÃO (continuação)

Filtragem com MAP Gamma Adaptado (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

a) LHH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	43	28	2
Área urbana	1	13	5
Agricultura	13	8	54

b) LHH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	79	6	3
Área urbana	13	14	5
Agricultura	3	9	79

c) LHH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	23	18	9
Área urbana	5	95	0
Agricultura	3	5	53

d) LHV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	16	5	6
Área urbana	19	33	2
Agricultura	8	10	36

e) LHV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	52	3	18
Área urbana	5	25	20
Agricultura	4	11	34

f) LHV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	11	5	6
Área urbana	17	21	55
Agricultura	5	3	35

APÊNDICE G – MATRIZES DE CUNFUSÃO (continuação)

Filtragem com MAP Gamma Adaptado (3x3), (5x5) e (7x7). Os resultados estão em porcentagem.

g) LVH 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	29	10	5
Área urbana	7	81	2
Agricultura	11	0	59

h) LVH 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	36	15	31
Área urbana	11	36	20
Agricultura	11	18	21

i) LVH 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	11	2	1
Área urbana	1	17	21
Agricultura	3	5	8

j) LVV 3x3

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	17	12	10
Área urbana	2	59	20
Agricultura	2	5	59

k) LVV 5x5

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	22	6	17
Área urbana	2	70	2
Agricultura	5	5	71

l) LVV 7x7

CLASSE	Cerrado	Área urbana	Agricultura
Cerrado	42	4	2
Área urbana	3	22	5
Agricultura	19	5	56

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, hiperespectrais 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 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:

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

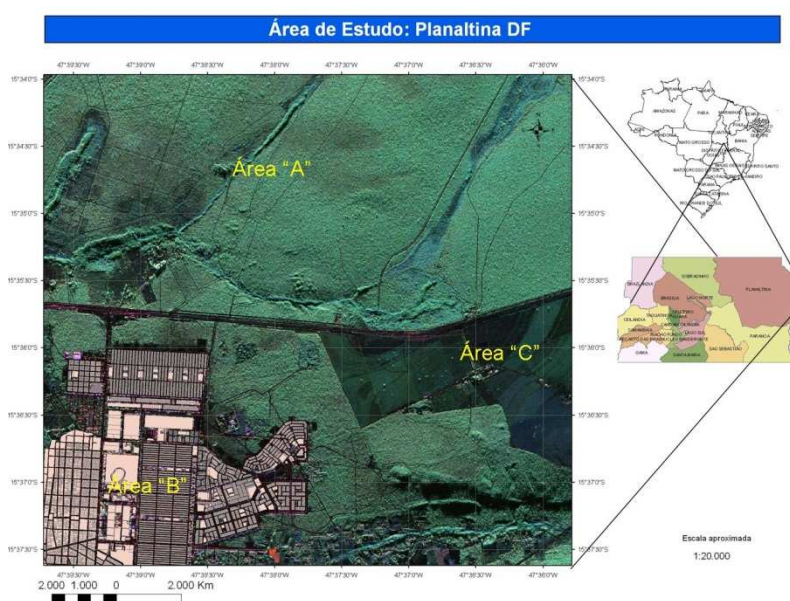


Figura 1 – localização da área de estudo

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.

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).

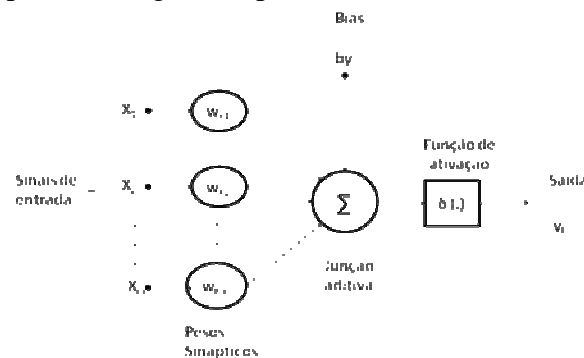


Figura 2 - Modelo de um neurônio de uma rede neural

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.

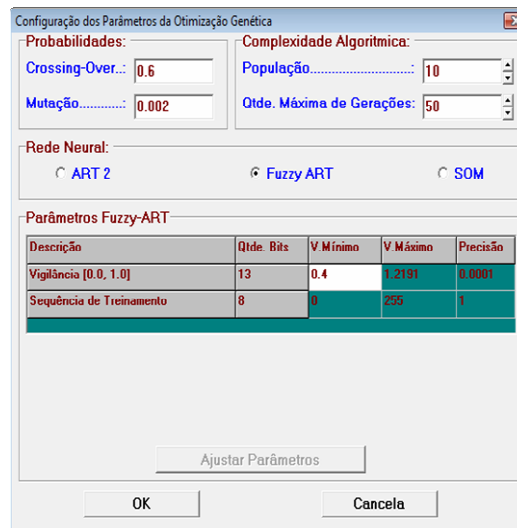
O agrupamento desses conceitos foi compilado para ser usado no classificador de SGRNA.

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).

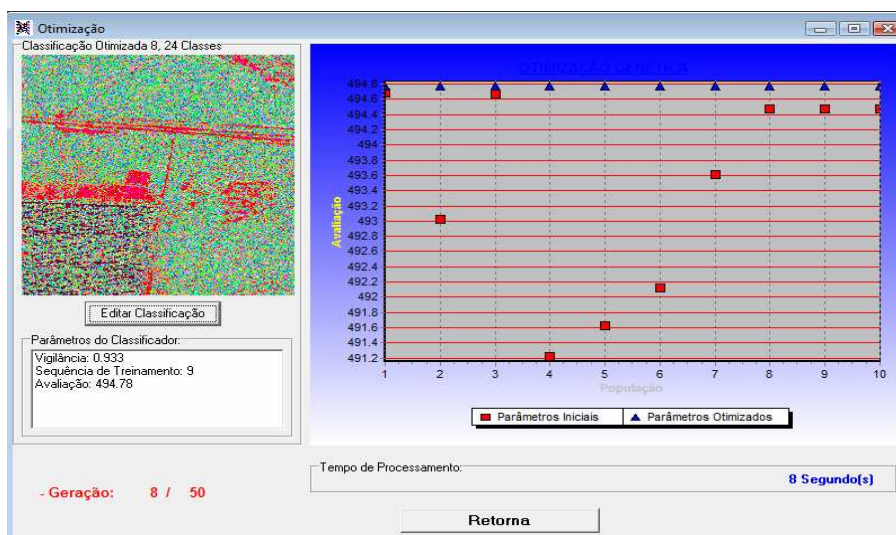


Figura 5 – resultado do processo de classificação.

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

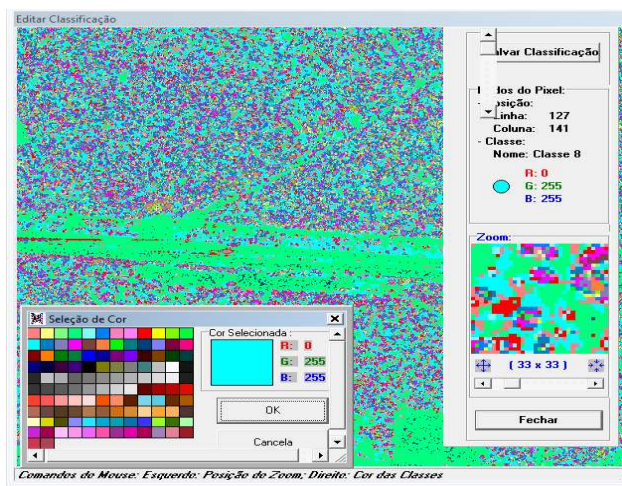


Figura 6 – Edição da classificação.

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.

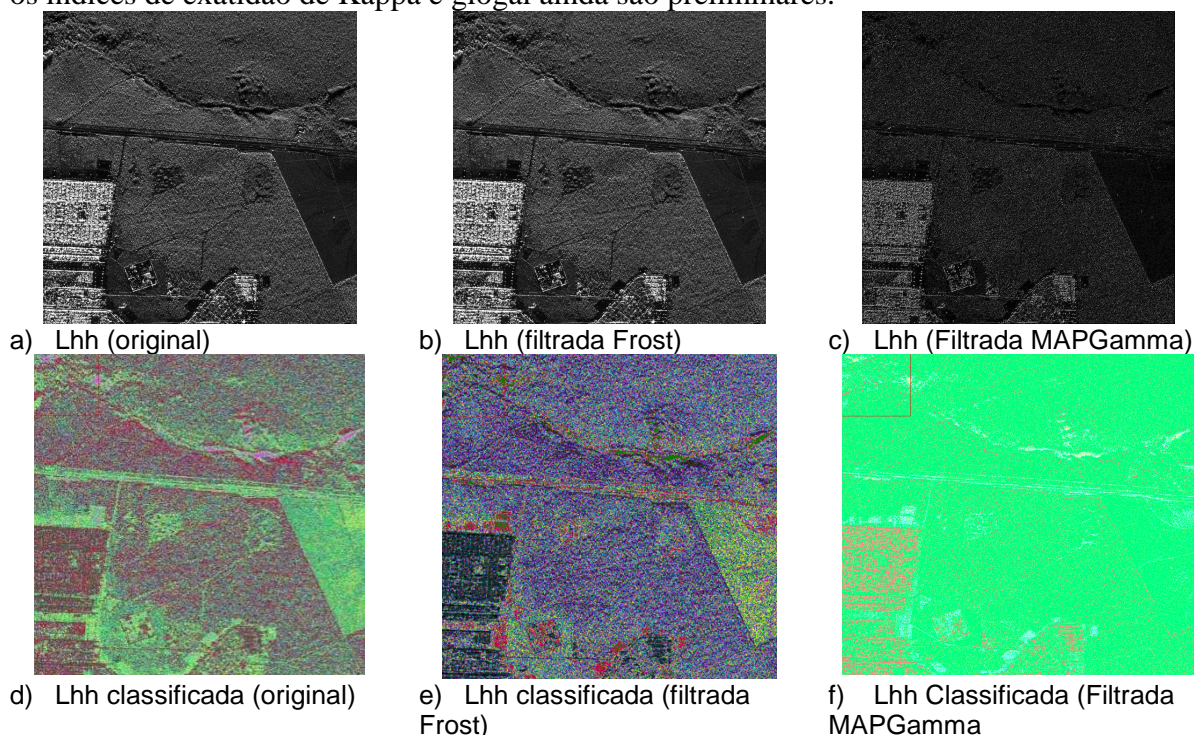


Figura 7 – Resultado da classificação gerada no SGRNA, na Banda L.

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., LACAVALA 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.