



UFAM

**UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
PRO-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
FACULDADE DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO STRICTO-SENSU EM CIÊNCIAS
FLORESTAIS E AMBIENTAIS - PPGCIFA**

**AVALIAÇÃO DE DADOS DE RADAR DO SENSOR SAR-R99B NO
MAPEAMENTO DO USO E COBERTURA DA TERRA NA AMAZÔNIA
CENTRAL, MUNICÍPIO DE MANAUS, AM.**

JORGE ALBERTO LOPES DA COSTA

**Manaus
2011**



UFAM

**UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
PRO-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
FACULDADE DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO STRICTU-SENSU EM CIÊNCIAS
FLORESTAIS E AMBIENTAIS**

JORGE ALBERTO LOPES DA COSTA

**AVALIAÇÃO DE DADOS DE RADAR DO SENSOR SAR-R99B NO
MAPEAMENTO DO USO E COBERTURA DA TERRA NA AMAZÔNIA
CENTRAL, MUNICÍPIO DE MANAUS, AM.**

Dissertação de Mestrado apresentada ao programa de Pós-Graduação em Ciências Florestais e Ambientais PPG/CIFA da Universidade Federal do Amazonas - UFAM, como parte dos requisitos necessários à obtenção do título de Mestre em Ciências Florestais e Ambientais, área de concentração Gestão Ambiental e Áreas Naturais Protegidas.

Orientador: Prof. Dr. Lizit Alencar da Costa

**Manaus
2011**

Ficha Catalográfica

(Catalogação realizada pela Biblioteca Central da UFAM)

Costa, Jorge Alberto Lopes da

837a Avaliação de dados de radar do sensor SAR-R99B no mapeamento do uso e cobertura da terra na Amazônia Central, município de Manaus, AM / Jorge Alberto Lopes da Costa. - Manaus: UFAM, 2011.

114 f.: il. color.

Dissertação (Mestrado em Ciências Florestais e Ambientais) — Universidade Federal do Amazonas, 2011.

Orientadora: Prof^a. Dra. Lizit Alencar da Costa


1. Mapeamento geológico 2. Sensoriamento Remoto 3. Processamento digital de imagens I. Costa, Lizit Alencar da (Orient.) II. Universidade Federal do Amazonas III. Título

CDU 528.8.044.2(811.3)(043.3)

FOLHA DOS EXAMINADORES

Dissertação de Mestrado apresentada ao programa de Pós-Graduação em Ciências Florestais e Ambientais PPG/CIFA da Universidade Federal do Amazonas - UFAM, como parte dos requisitos necessários à obtenção do título de Mestre em Ciências Florestais e Ambientais. Avaliada e aprovada em 07 de Julho de 2011.

BANCA EXAMINADORA



Dr. Lizit Alencar da Costa
Presidente da Banca
Universidade Federal do Amazonas - UFAM



Dr. Luciano Vieira Dutra
Membro
Instituto Nacional de Pesquisas Espaciais- INPE



Dr.ª Corina da Costa Freitas
Membro
Instituto Nacional de Pesquisas Espaciais - INPE

Aluno: Jorge Alberto Lopes da Costa

**Manaus
2011**

AGRADECIMENTOS

À Deus pela Saúde, Disposição e Alegria, necessárias para enfrentar as dificuldades dessa jornada.

Aos meus pais, por sempre acreditarem na importância do estudo e por sempre apoiarem meus objetivos.

A minha família pelo o apoio e compreensão durante os momentos de ausência.

A UFAM – Universidade Federal do Amazonas, que me recebeu na graduação e onde tive a oportunidade de fazer este Mestrado.

Ao PPG CIFA Programa de pós-graduação em ciências florestais e Ambientais, onde pude desenvolver minha pesquisa.

Ao meu Orientador Professor Dr. Lizit Alencar da Costa, que depositou em mim confiança e pelo conhecimento, orientação e apoio prestados durante esta jornada.

Ao corpo docente do Mestrado em Ciências Florestais e Ambientais pela passagem de conhecimento e opiniões expressadas em sala de aula.

Ao SIPAM pelo apoio e disponibilização dos dados SAR-R99B

A todos os colegas do Mestrado, em especial: Milvania Maria, Rogerio Silva, Aldilane, Ruth, Roberta Moura, Marcos, Tadeu e Stiffanni pela convivência durante o curso.

Aos amigos Ulisses Rocha e Francisco Bittencourt pelo apoio durante a campanha de trabalho de campo.

A DEUS. Sem FÉ, nada disso seria possível!

RESUMO

Nas últimas décadas as áreas de floresta tropical na região Amazônica têm sido fortemente impactada por um rápido processo de conversão da cobertura vegetal em outros tipos de uso devido à ação antrópica. No contexto das mudanças globais, os mapeamentos e monitoramentos de uso e cobertura da terra fornecem subsídios para as análises e avaliações dos impactos ambientais em virtude de acelerados processos de mudança na paisagem. Neste contexto, este estudo avaliou o potencial dos dados de radar de abertura sintética para discriminação de uso e cobertura da terra na região de Manaus, estado do Amazonas. Foi utilizada uma imagem multipolarizada do sensor aerotransportado SAR-R99B (banda L), com 3 metros de resolução espacial. Realizaram-se classificações na imagem radar sem filtro e com filtro *Gamma* 3x3. Avaliou-se o classificador pontual MAXVER-ICM e o SVM (*Support Vector Machine*), onde em todos os casos utilizou-se das imagens multipolarizadas em amplitude individualmente (HH, HV e VV), aos pares (HH e HV), (HV e VV) e (HH e VV) e em conjunto (HH, HV e VV). Os resultados obtidos foram comparados utilizando-se como parâmetro o coeficiente de concordância Kappa. O classificador SVM apresentou acurácia superior em relação ao classificador MAXVER-ICM. As melhores classificações foram obtidas para a polarização dual HH e VV com o classificador MAXVER-ICM e (HH, HV e VV) com o classificador SVM ambos utilizando as imagens com filtro. A acurácia mais elevada foi para a classificação com SVM e imagens com filtro ($kappa = 0,7736$). Analisou-se a influência do uso de filtro *GAMMA* no desempenho dos classificadores onde se constatou que as imagens filtradas proporcionaram um incremento nos resultados, em média, na ordem de 8%. Deste modo realizou-se a análise dos resultados das classificações, onde se constatou que o melhor resultado foi proporcionado pelo conjunto de dados multipolarizados (HH, HV e VV) classificados através do método SVM. Assim, concluiu-se que o uso de imagens de radar no mapeamento de classes temáticas de uso e cobertura da terra, em regiões tropicais, pode ser considerado como uma proposta viável.

Palavras-chave: Uso e cobertura da terra; Sensoriamento Remoto; RADAR; SAR-R99B; SVM; MAXVER-ICM.

ABSTRACT

In recent decades the areas of rainforest in the Amazon region has been heavily impacted by a rapid process of conversion of vegetation cover in other types of use due to human action. In the context of global change, the use of mapping and monitoring land cover and provide information for the analysis and evaluation of environmental impacts due to accelerated changes in the landscape. Therefore, this study evaluated the potential of data from synthetic aperture radar for discriminating use and land cover in the region of Manaus, Amazonas state. We used a multipolarized image from sensor airborne SAR-R99B (L band), with 3 m spatial resolution. Were evaluated the MAXVER-ICM and SVM (Support Vector Machine) classifiers, where in all cases we used the images individually multipolarized amplitude (HH, HV and VV), in pairs (HH and HV), (HV and VV) and (HH and VV) and together (HH, HV and VV). The results were compared using as parameter the Kappa coefficient. The SVM classifier had higher accuracy compared to MAXVER-ICM classifier. The best classifications were obtained for the dual polarization (HH and VV) with MARVER-ICM classifier and (HH, HV and VV) with the SVM classifier both using the images with the filter. The accuracy was highest with SVM for classification and filter images ($\kappa = 0.7736$). Were analyzed the influence of using GAMMA filter performance on the classifiers where it showed that filtered images have provided an increase in the results, on average, about 8%. Thus there was the analysis of the classification results, which found that the best result was provided by the dataset multipolarized (HH, HV and VV) classified by the SVM method. Thus, we concluded that the use of radar imagery in mapping thematic classes use and land cover in tropical regions, can be considered as a viable proposal.

Key-Words: Land Use Land Cover; remote sensing; Synthetic Aperture Radar; SAR-R99B; MAXVER-ICM; Support Vector Machine.

LISTA DE FIGURAS (ILUSTRAÇÕES)

Figura 1 - Ilustração da probabilidade de obtenção de cenas do sensor LandSat na região Amazônica.	13
Figura 2 - Espectro eletromagnético e bandas da região de microondas.....	18
Figura 3 - Espectro de Microondas e a identificação das bandas por letras.....	20
Figura 4 - Geometria de aquisição de imagens por radares aerotransportado.....	20
Figura 5 - Tipos de Mecanismos de retroespalhamento em ambientes florestais.....	22
Figura 6 - Modos de imageamento polarimétrico em sistema de radar aerotransportado.....	24
Figura 7 - Relação entre os ângulos de incidência nos sistemas.....	25
Figura 8 - Comparação entre imageamentos orbital e aerotransportado.....	25
Figura 9 - Modelo de padrões de espalhamento em sistema aerotransportado.....	26
Figura 10 - Modo de mapeamento do Sensor SAR-R99B.....	33
Figura 11 - Localização geográfica da área de estudo.....	39
Figura 12 - Modo de coleta das imagens SAR.....	42
Figura 13 - Disposição da área teste.....	43
Figura 14 - Imagens SAR-R99B da área de estudo.....	44
Figura 15 - Gráfico representativo de precipitação pluviométrica mensal do ano 2009.....	46
Figura 16 - Gráfico dos valores diários da umidade relativa do ar para o mês de Maio de 2009.....	46
Figura 17 - Fluxograma da metodologia geral do trabalho.....	47
Figura 18 - Fluxograma da sequência dos procedimentos realizados no pré-processamentos dos dados SAR-R99B.....	48
Figura 19 - Distribuição espacial dos pontos de controle coletados em campo.....	50
Figura 20 - Médias dos pixels (Radiometria) ao longo do azimute para um dado <i>range</i>	51
Figura 21 - Recorte da área de estudo	52
Figura 22 - Feições representativas da área de estudo	54
Figura 23 - Distribuição das classes sobre imagem em composição colorida com as Polarizações (VV)G(HV)B(HH)	54
Figura 24 - Classificação MAXVER-ICM, utilizando a polarização HH sem filtro.....	63
Figura 25 - Classificação MAXVER-ICM, utilizando a polarização HV sem filtro.....	64
Figura 26 - Classificação MAXVER-ICM, utilizando a polarização VV sem filtro.....	65
Figura 27 - Classificação MAXVER-ICM, utilizando a polarização HH+HV sem filtro.....	66
Figura 28 - Classificação MAXVER-ICM, utilizando a polarização HV+VV sem filtro.....	67
Figura 29 - Classificação MAXVER-ICM, utilizando a polarização HH+VV sem filtro.....	68

Figura 30 - Classificação MAXVER-ICM, utilizando a polarização HH+HV+VV sem filtro.....	69
Figura 31 - Classificação MAXVER-ICM, utilizando a polarização HH (filtro <i>Gamma 3x3</i>).....	72
Figura 32 - Classificação MAXVER-ICM, utilizando a polarização HV (filtro <i>Gamma 3x3</i>).....	73
Figura 33 - Classificação MAXVER-ICM, utilizando a polarização VV (filtro <i>Gamma 3x3</i>).....	74
Figura 34 - Classificação MAXVER-ICM, utilizando as polarizações HH+HV (filtro <i>Gamma 3x3</i>).....	75
Figura 35 - Classificação MAXVER-ICM, utilizando as polarizações HH+HV (filtro <i>Gamma 3x3</i>).....	76
Figura 36 - Classificação MAXVER-ICM, utilizando as polarizações HH+HV (filtro <i>Gamma 3x3</i>).....	77
Figura 37 - Classificação MAXVER-ICM, utilizando as polarizações HH+HV (filtro <i>Gamma 3x3</i>).....	78
Figura 38 - Classificação SVM, utilizando a polarização HH sem filtro.....	82
Figura 39 - Classificação SVM, utilizando a polarização HV sem filtro.....	83
Figura 40 - Classificação SVM, utilizando a polarização VV sem filtro.....	84
Figura 41 - Classificação SVM, utilizando a polarização HH+HV sem filtro.....	85
Figura 42 - Classificação SVM, utilizando a polarização HV+VV sem filtro.....	86
Figura 43 - Classificação SVM, utilizando a polarização HH+VV sem filtro.....	87
Figura 44 - Classificação SVM, utilizando a polarização HH+HV+VV sem filtro.....	88
Figura 45 - Classificação SVM, utilizando a polarização HH com filtro <i>Gamma 3x3</i>	91
Figura 46 - Classificação SVM, utilizando a polarização HV com filtro <i>Gamma 3x3</i>	92
Figura 47 - Classificação SVM, utilizando a polarização VV com filtro <i>Gamma 3x3</i>	93
Figura 48 - Classificação SVM, utilizando a polarização HH+HV com filtro <i>Gamma 3x3</i> ..	94
Figura 49 - Classificação SVM, utilizando a polarização HV+VV com filtro <i>Gamma 3x3</i> ..	95
Figura 50 - Classificação SVM, utilizando a polarização HH+VV com filtro <i>Gamma 3x3</i> ..	96
Figura 51 - Classificação SVM, utilizando a polarização HH +HV+VV com filtro <i>Gamma 3x3</i>	97
Figura 52 - Distribuição dos índices Kappa das classificações SVM das imagens em amplitude sem filtro e com filtro (<i>Gamma 3x3</i>).....	98
Figura - 53 - Distribuição dos índices Kappa das classificações SVM das imagens em amplitude sem filtro e com filtro (<i>Gamma 3x3</i>).....	98
Figura 54 - Mapa temático resultante da classificação SVM com os dados multipolarizados.....	101

LISTA DE TABELAS

TABELA 1 - Bandas de Sensores de Radar imageadores.....	23
TABELA 2 - Conceitos das classificações baseados no coeficiente <i>Kappa</i>	32
TABELA 3 - Características do Sensor SAR-R99B.....	34
TABELA 4 - Características da imagem em modo de operação.....	42
Tabela 5 - Chave da Interpretação das Classes Temáticas.....	55
TABELA 6 - Número de amostras e pixels referente as classes temáticas utilizados nas fases de treinamento e teste.....	56
TABELA 7 - Resultado geral de exatidão das classificações MAXVER-ICM para as imagens em amplitude sem filtro.....	61
TABELA 8 - Matriz de confusão da classificação MAXVER-ICM, canal HH sem filtro.....	63
TABELA 9 - Matriz de confusão da classificação MAXVER-ICM, canal HV sem filtro.....	64
TABELA 10 - Matriz de confusão da classificação MAXVER-ICM, canal VV sem filtro.....	65
TABELA 11 - Matriz de confusão da classificação MAXVER-ICM , canais HH +HV sem filtro.....	66
TABELA 12 - Matriz de confusão da classificação MAXVER-ICM, canais HV +VV sem filtro.....	67
TABELA 13 - Matriz de confusão da classificação MAXVER-ICM, HH +VV sem filtro.....	68
TABELA 14 - Matriz de confusão da classificação MAXVER-ICM , canais VV+HV+HH sem filtro.....	69
TABELA 15 - Resultado geral (exatidão) das classificações MAXVER-ICM para a imagem em amplitude com filtro <i>Gamma</i> 3x3.....	70
TABELA 16 - Matriz de confusão da classificação MAXVER-ICM , canal HH (filtro <i>Gamma</i> 3x3).....	72
TABELA 17 - Matriz de confusão da classificação MAXVER-ICM , canal HV (filtro <i>Gamma</i> 3x3).....	73
TABELA 18 - Matriz de confusão da classificação MAXVER-ICM, canal VV (filtro <i>Gamma</i> 3x3).....	74
TABELA 19 - Matriz de confusão da classificação MAXVER-ICM, canais HH+HV (filtro <i>Gamma</i> 3x3).....	75
TABELA 20 - Matriz de confusão da classificação MAXVER-ICM, canais HV+VV (filtro <i>Gamma</i> 3x3).....	76
TABELA 21 - Matriz de confusão da classificação MAXVER-ICM, canais HH+VV (filtro <i>Gamma</i> 3x3).....	77
TABELA 22 - Matriz de confusão da classificação MAXVER-ICM, canais VV+HV+ HH (filtro <i>Gamma</i> 3x3).....	78

TABELA 23 - Resultado geral de exatidão das classificações SVM para a imagem em amplitude sem filtro.....	80
TABELA 24- Matriz de confusão da classificação SVM, canal HH sem filtro.....	82
TABELA 25 - Matriz de confusão da classificação SVM, canal HV sem filtro.....	83
TABELA 26 - Matriz de confusão da classificação SVM, canal VV sem filtro.....	84
TABELA 27 - Matriz de confusão da classificação SVM, canais HH+HV sem filtro.....	85
TABELA 28 - Matriz de confusão da classificação SVM, canais HV+VV sem filtro.....	86
TABELA 29 - Matriz de confusão da classificação SVM, canais HH+VV sem filtro.....	87
TABELA 30 - Matriz de confusão da classificação SVM, canais HH+HV+VV sem filtro..	88
TABELA 31 - Resultado geral de exatidão das classificações SVM para a imagem em amplitude com filtro <i>Gamma</i> 3x3.....	89
TABELA 32 - Matriz de confusão da classificação SVM, canal HH (filtro <i>Gamma</i> 3x3)	91
TABELA 33 - Matriz de confusão da classificação SVM, canal HV (filtro <i>Gamma</i> 3x3).....	92
TABELA 34 - Matriz de confusão da classificação SVM, canal VV (<i>Gamma</i> 3x3).....	93
TABELA 35 - Matriz de confusão da classificação SVM, canais HH+ HV (filtro <i>Gamma</i> 3x3).....	94
TABELA 36 - Matriz de confusão da classificação SVM, canais HV+VV (filtro <i>Gamma</i> 3x3).....	95
TABELA 37 - Matriz de confusão da classificação SVM, canais HH+VV (filtro <i>Gamma</i> 3x3).....	96
TABELA 38 - Matriz de confusão da classificação SVM, canais HH+HV+VV (<i>Gamma</i> 3x3).....	97

SUMARIO

1. INTRODUÇÃO.....	11
1.1 JUSTIFICATIVA	15
1.2 CONVENÇÕES ADOTADAS	17
1.3 HIPÓTESE	17
2. OBJETIVOS.....	18
2.1. GERAL.....	18
2.2. ESPECÍFICOS	18
3. FUNDAMENTAÇÃO TEÓRICA	19
3.1. USO E COBERTURA DA TERRA.....	19
3.2. ASPECTOS BÁSICOS DE SENSORIAMENTO REMOTO POR RADAR	20
3.2.1 CARACTERÍSTICAS.....	21
3.2.3 PARÂMETROS DO SISTEMA (RADAR).....	24
3.2.3.1 COMPRIMENTO DE ONDA (λ).....	24
3.2.3.2 POLARIZAÇÃO	25
3.2.3.3 ÂNGULO DE INCIDÊNCIA (θ).....	26
3.2.3.4 COMPORTAMENTO DOS ALVOS	28
3.2.3.5 CONSTANTE DIELÉTRICA.....	28
3.2.4 RUÍDO SPECKLE	29
3.3 CLASSIFICAÇÃO DIGITAL DE IMAGENS	30
3.3.1 CLASSIFICAÇÃO MAXVER-ICM.....	31
3.3.2 CLASSIFICAÇÃO SVM (<i>SUPPORT VECTOR MACHINE</i>)	32
3.4 AVALIAÇÕES DAS CLASSIFICAÇÕES	33
3.5 O SENSOR SAR-R99B	35
3.5.1 CARACTERÍSTICAS.....	35
3.6. USO E APLICAÇÃO DE DADOS SAR.....	38
4 MATERIAIS E MÉTODO.....	41
4.1 ÁREA DE ESTUDO	41
4.1.1. CLIMA	42
4.1.2. SOLO E RELEVO	42
4.1.3. VEGETAÇÃO.....	43
4.2 MATERIAIS UTILIZADOS.....	44
4.2.1. IMAGENS SAR-R99B.....	44

4.2.2. APLICATIVOS E HARDWARE UTILIZADOS.....	47
4.2.3. DADOS AUXILIARES	47
4.2.3.1. DADOS PLUVIOMÉTRICOS	47
4.3. METODOLOGIA.....	49
4.3.1 PRÉ-PROCESSAMENTO	50
4.3.1.1 CORREÇÃO GEOMÉTRICA	51
4.3.1.2 CORREÇÃO DE PADRÃO DE ANTENA.....	52
4.3.1.3 FILTRAGEM DO RUÍDO (<i>SPECKLE</i>).....	54
4.3.2 DEFINIÇÃO E CARACTERIZAÇÃO DAS CLASSES TEMÁTICAS.....	55
4.3.2.2 AMOSTRAS DE TREINAMENTO E TESTE	58
4.3.3 AVALIAÇÃO DOS CLASSIFICADORES MAXVER-ICM E SVM.....	59
4.3.3.1. CLASSIFICAÇÃO PELO MÉTODO MAXVER-ICM.....	59
4.3.3.2 CLASSIFICAÇÃO PELO MÉTODO SUPPORT VECTOR	60
MACHINE (SVM)	60
4.3.4 AVALIAÇÃO DA ACURÁCIA TEMÁTICA	60
5. RESULTADOS E DISCUSSÕES.....	62
5.1 AVALIAÇÃO DOS CLASSIFICADORES MAXVER-ICM E <i>SUPPORT VECTOR</i>	
<i>MACHINE</i> (SVM).	63
5.1.2 CLASSIFICAÇÃO (MAXVER-ICM).....	63
5.1.2.1 MAXVER-ICM (IMAGENS SEM FILTRO).....	63
5.1.2.2 MAXVER-ICM (IMAGENS FILTRADAS COM <i>GAMMA 3X3</i>).....	72
5.1.3 CLASSIFICAÇÃO <i>SUPPORT VECTOR MACHINE</i> (SVM)	81
5.1.3.1 SUPPORT VECTOR MACHINE (IMAGENS SEM FILTRO).....	82
5.1.3.2 SUPPORT VECTOR MACHINE_(IMAGENS FILTRADAS - <i>GAMMA 3X3</i>)	91
5.2 ANÁLISE DA INFLUÊNCIA DO USO DE FILTRO <i>GAMMA 3X3</i>	100
5.3. INDICAÇÃO DO MELHOR CONJUNTO (CLASSIFICADOR, POLARIZAÇÃO,	
IMAGEM BRUTA OU IMAGEM FILTRADA) PARA DISCRIMINAÇÃO DAS	
CLASSES TEMÁTICAS.	102
6. DISCUSSÕES	104
7. CONCLUSÕES E RECOMENDAÇÕES.....	106
8. REFERÊNCIAS	108

1. INTRODUÇÃO

Nas últimas décadas as áreas de floresta tropical na região Amazônica têm sido fortemente impactada por um rápido processo de conversão da cobertura vegetal em outros tipos de uso devido a ação antrópica. A perda da cobertura vegetal na região compromete significativamente a preservação e a conservação da biodiversidade, assim como, causa grande impacto ao meio ambiente. O processo de ocupação na Amazônia tem contribuído, de forma significativa, para o aumento na perda de áreas de floresta na região. Estudos realizados mostram que grande parte das modificações na cobertura da terra na região Amazônica é causada pelo processo de desflorestamento, o qual está fortemente atrelado às questões econômicas e políticas de desenvolvimento aplicados na região amazônica (ALENCAR *et al.*, 2004; FEARNSTIDE, 2003; LAURANCE *et al.*, 2004), os quais já contribuíram para a perda de 17,9% da cobertura florestal primária na região da Amazônia Legal (INPE, 2008).

Os mapeamentos de uso e cobertura da terra indicam a distribuição geográfica da tipologia de uso as quais são identificadas através técnicas de reconhecimento de padrões homogêneos da cobertura terrestre visando a sua classificação e espacialização através de mapas, IBGE (2006).

Os estudos de identificação e monitoramento da cobertura da terra com dados de sensoriamento remoto pressupõem que as alterações provocadas na superfície terrestre, sejam elas causadas de forma antrópica ou natural, serão identificadas nas imagens produzidas através de sensores.

Na região Amazônica o monitoramento das alterações da cobertura da terra permite identificar a dinâmica dos fenômenos ocorridos na paisagem, possibilitando o acompanhamento sistemático e auxiliando no entendimento das causas geradoras dos processos antrópicos.

O uso de sensores remotos tem sido uma das ferramentas amplamente utilizada pela comunidade científica, pois os dados adquiridos através de sensores remotos, sejam eles orbital ou aerotransportado, têm sido empregados com sucesso em aplicações que envolvem grandes extensões territoriais e permitido estudos com resultados cada vez mais promissores (HYPPA *et al.*, 2000; KERR, 2003).

Várias pesquisas foram realizadas utilizando dados de radar, as quais demonstraram o potencial desses dados no monitoramento da cobertura vegetal na região Amazônica (SHIMABUKURO *et al.*, 1998; SAATCHI *et al.*, 2000; FREITAS *et al.*, 2008). Entretanto, a identificação das classes de uso e cobertura através do uso de imagens de radar de abertura

sintética (SAR) está condicionada a parâmetros do sensor, como: polarização, banda de imageamento e ângulo de incidência.(LECKIE et al., 1998). Conforme Almeida-Filho et al. (2009) e Bufalo (2005) o uso de dados monopolarizados da banda L (HH) apresentou limitações na identificação de áreas de floresta primária, áreas de floresta degradada ou desflorestamentos recentes.

Neste contexto, a contribuição principal desta dissertação é avaliar o potencial dos dados de radar de abertura sintética SAR polarimétricos em banda L de alta resolução adquiridos pelo sensor aerotransportado SAR-R99B, por meio de técnica de classificação automática para discriminação de uso e cobertura da terra na região de Manaus, estado do Amazonas.

1.1 JUSTIFICATIVA

A manutenção e preservação da floresta Amazônica é de suma importância para a conservação dos ecossistemas da região. A Floresta Amazônica é considerada como a região de maior diversidade do mundo. Dentro do território brasileiro inicialmente a área de florestais tropicais ocupava aproximadamente uma área de 4 milhões de km², sendo que atualmente somente 82,2% deste total encontram-se preservados (ALVES, 2007; MALHI *et al.*, 2008; PRODES, 2009).

O monitoramento do uso e cobertura do solo através de dados de sensores remotos nos permite criar subsídios para a identificação de uma série de problemas ambientais decorrente da mudança da paisagem. Na região Amazônica as modificações na cobertura da terra têm se tornado mais intensas devido ao crescimento demográfico na região (JANSEN; DI GREGÓRIO, 2002). Segundo Margulis (2003) tal processo intensificou-se no início da década de 1990, devido à expansão da pecuária, exploração seletiva de madeira e utilização da agricultura mecanizada, o que gerou um aumento significativo do desflorestamento na região. Dados coletados, através sensores remotos, em diferentes comprimento de ondas do espectro eletromagnético juntamente com dados gerados a partir de trabalho de campo, abriram uma nova fase nos estudos sobre observação da terra (ABER e MELLILO, 2001).

O sensoriamento remoto é a principal fonte de obtenção de informações para estudos de mapeamento e monitoramento de uso e cobertura do solo na região amazônica. Entretanto, a ocorrência de constante cobertura de nuvens em regiões de florestas tropicais dificulta o monitoramento desses ambientes quando se utiliza dados coletados por sensores ópticos. Segundo Asner (2001), a probabilidade anual de obtenção de uma imagem de sensor óptico livre de cobertura de nuvens na região amazônica chega a ser inferior a 10%. (Figura 1).

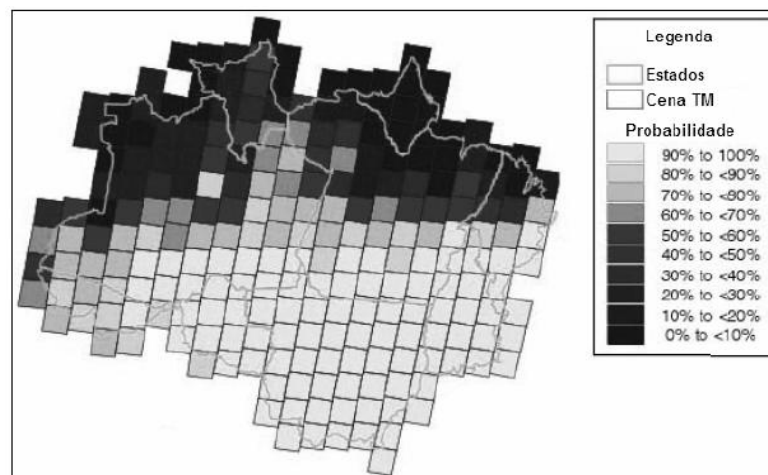


Figura 1: Ilustração da probabilidade de obtenção de cenas do sensor Landsat na região Amazônica.
Fonte: Adaptado de Asner (2001)

Nas regiões tropicais os dados de radar de abertura sintética SAR (Synthetic Aperture Radar) se tornam especialmente úteis, em face das restrições impostas ao imageamento óptico pela constante presença de nuvens e neblina, e por acrescentar informações além das já fornecidas pelos dados oriundos de sensores ópticos, sendo mais um ponto a favor no processo de detecção de mudança do uso e cobertura do solo, possibilitando a quantificação e qualificação do dossel de florestas (ROSENQVIST *et al.*, 2003).

Vários estudos realizados em regiões de florestas tropicais evidenciaram o potencial dos dados de radares de abertura sintética (SAR) oriundos de diversos sensores (ex: ERS-1, JERS-1, RADARSAT e ALOS/PALSAR), dos quais podemos citar: (ABOUD NETA, 2009; BALZTER, 2001; DOBSON *et al.*, 1999; DUTRA *et al.*, 1999; GUERRA *et al.*, 2009; LE TOAN *et al.*, 1992; MAYAUX *et al.*, 2002; SANTOS *et al.*, 2002; SANTOS *et al.*, 2003; SGRENZAROLLI *et al.*, 2004;) .

A mais recente contribuição para o monitoramento e mapeamento na Amazônia surgiu através do programa do Sistema de Proteção da Amazônia – SIPAM. O sensor de radar de abertura sintética SAR-R99B difere dos demais sensores, pela capacidade de imageamento simultâneo com a banda L, nas polarizações HH, VV, VH e HV, e banda X (HH), com resoluções espaciais de 3 m, 6 m e 18 m.

A disponibilidade de imagens de radar, com capacidade polarimétrica e alta resolução espacial, permite uma melhora significativa no potencial de discriminação de alvos em superfícies alteradas. O surgimento de novos sensores além de produzirem dados multipolarizados, apresentam uma expressiva melhora no quesito de resolução espacial e temporal, com isso, aumenta-se a capacidade de monitoramento em regiões de florestas tropicais.

Entretanto, todos esses dados necessitam de avaliação afim de identificar a eficácia de tal dados conforme as diversas aplicações em que podem ser empregados. Nesse contexto, as pesquisas utilizando dados de radar de alta resolução espacial ainda são incipientes para discriminação de uso e cobertura da terra. Portanto neste estudo pretende-se acrescentar conhecimento que permita a utilização das informações obtidas com intuito de subsidiar programas que visam o mapeamento e monitoramento de uso e cobertura da terra em regiões tropicais, os quais são de extrema importância como ferramentas para as ações de políticas públicas governamentais voltadas para o controle e prevenção do meio ambiente.

1.2 CONVENÇÕES ADOTADAS

- Dados multipolarizados ou multivariados: É o conjunto de dados composto pelas imagens amplitude das componentes HH, HV e VV. Por conveniência, tal conjunto será representado por {HH,HV,VV};
- Dados univariados: É o dado composto pela informação de amplitude de apenas um canal (HH, HV ou VV);
- Dados bivariados: É o conjunto de dados composto pela informação de amplitude obtidos da combinação de dois canais {HH,HV}, {HV,VV} ou {HH,VV};
- SAR-R99B: Refere-se ao sensor SAR aerotransportado R99B.

1.3 HIPÓTESE

Este trabalho tem como hipótese que é possível discriminar classes de uso e cobertura da terra na Amazônia de modo automático com dados do sensor SAR-R99B.

2. OBJETIVOS

2.1. GERAL

Avaliar a potencialidade dos dados multipolarizados do sensor remoto aerotransportado SAR-R99-B em banda L, através do uso de técnicas de processamento digital de imagens por meio de classificação automática para a identificação, extração e quantificação de classes de uso e cobertura da terra na região da Amazônia central.

2.2. ESPECÍFICOS

Como desdobramentos desse objetivo geral, destacam-se os seguintes objetivos específicos:

i) Avaliar a performance dos classificadores supervisionados MAXVER-ICM e SVM (Support Vector Machine) em dados multipolarizados;

ii) Analisar a influência do uso de filtro, para redução de ruído nos dados multipolarizados;

iii) Determinar o melhor conjunto (classificador, polarização, imagem bruta ou imagem filtrada) para discriminação de classes temáticas.

3. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os conceitos teóricos e trabalhos anteriores que direcionaram este estudo.

3.1. USO E COBERTURA DA TERRA

O estudo sobre a transformação da superfície da terra pode ser dividido em dois componentes inter-relacionados: uso da terra e cobertura da terra.

De acordo com [Turner e Meyer \(1994\)](#) o uso da terra é um termo utilizado na área de ciências sociais que denota a utilização da terra pelo homem para fins de atividades como: cultivos agrícolas, pastagens, recreação e etc. Mudança de uso e cobertura da terra em uma determinada localidade pode ocorrer de duas formas, uma troca de um tipo de uso para outro ou intensificação de uso corrente, ressaltando que cada tipo de uso corresponde a uma cobertura.

O termo cobertura da terra denota o estado físico da terra, à cobertura biofísica observadas na superfície terrestre, ou seja, os corpos d'água, rochas, a quantidade e tipo de vegetação. As transformações da cobertura podem ser de uma classe para outra ou estar ligada à condição de um tipo de cobertura, como a degradação de uma floresta em diferentes níveis, [Escada \(2003\)](#).

Segundo [Green et al \(1994\)](#), as implicações das mudanças no uso e cobertura da terra ocorrem em função do contexto social, econômico, político e ecológico da região em que se encontram. Estas implicações promovem uma série de impactos em diversas escalas.

Dentre os impactos causados pode-se relacionar os referentes à perda da biodiversidade e os de danos sociais, provocados por ação antrópica ou pela natureza com potencial de mudança da paisagem em um determinado espaço de tempo, [\(WALKER, 2004\)](#).

No Brasil, os primeiros registros de pesquisas sobre uso e cobertura da terra são das décadas de 30 e 40. Segundo [IBGE \(2006\)](#), os primeiros trabalhos tinham como objetivo realizar o levantamento e reconhecimento de áreas pouco conhecidas e estudar o processo de colonização que estava ocorrendo naquele momento .

Nas duas décadas seguintes os trabalhos focaram em atividades de identificação de padrões espaciais de cobertura, com objetivo de caracterizar distribuições de propriedades e frentes pioneiras visando abordar questões regionalizadas sobre uso e

cobertura. Tais esforços possibilitaram avanços significativos sobre a classificação e entendimento sobre a dinâmica de uso da terra a partir da criação de uma terminologia padronizada.

De acordo com [Lambin et al. \(2003\)](#), visto a influência existente entre a cobertura da terra e os processos climáticos, as iniciativas de monitoramento do uso e cobertura da terra ganharam destaques nas discussões sobre alterações climáticas globais. Estudos evidenciaram que existe uma estreita relação entre os impactos e alterações em ecossistemas com às alterações da superfície terrestre.

3.2. ASPECTOS BÁSICOS DE SENSORIAMENTO REMOTO POR RADAR

Os sistemas de radares (Radio Detection Ranging) utilizam ondas eletromagnéticas na faixa de microondas. São considerados sensores ativos por possuírem a capacidade de gerar sua própria radiação cujo comprimento de onda varia entre 1cm a 1,5m (0.3 a 300 Ghz) Figura 2. Sensores que operam na faixa de microondas podem adquirir dados independentemente da radiação solar e em condições meteorológicas adversas ([SABINS, 1996](#); [MATHER,1999](#); [JENSEN, 2007](#)). Em sistemas ativos a antena transmite sinal em microondas em direção aos alvos na superfície terrestre onde o sinal emitido é retroespalhado. A parte da energia eletromagnética espalhada na direção da antena é detectada e coletada pelo sensor.




Figura 2: Espectro eletromagnético e bandas da região de microondas.

Fonte: Adaptada de [Dallemand et al. \(1993\)](#).

Os sistemas de radar podem ser divididos em dois grupos: imageadores e não imageadores. No grupo dos não imageadores incluem-se o escaterômetro, que mede informações sobre as propriedades dos objetos (ex. velocidade do vento) e os altímetros,

que coletam informações em distância (ex. nível dos mares). Os radares imageadores compreendem os sistemas constituídos de antenas rotatória e os de visada lateral (SLAR – Side Looking Airborne Radar). A definição de SLAR engloba os radares do tipo RAR (Real Aperture Radar) radar de abertura real e o SAR (Synthetic Aperture Radar) radar de abertura sintética.

O princípio do funcionamento do radar imageador consiste na emissão de radiação eletromagnética na faixa de microondas direcionada a uma porção da superfície, registrando a intensidade e o tempo de retorno desse pulso de energia retroespalhada em direção à antena portando características como comprimento de onda (λ), amplitude, polarização, fase e direção de propagação da onda (HENDERSON & LEWIS, 1998).

A parte do sinal que retorna e é captada pela antena é estruturada na forma de um dado SAR complexo, decomposto em duas partes: sinal em fase (I: *In Phase*) e sinal em quadratura de fase (Q: *Quadrature*). O sinal é convertido em representação numérica e armazenado na forma de um número complexo, onde a parte real contém o componente do sinal em fase (I) e a parte imaginária contém o componente em quadratura de fase (Q). Posteriormente o sinal é transmitido à estação de recepção em terra. Essa imagem complexa é denominada de *Single Look Complex* (SLC) (CCRS, 2008; GABOARDI, 2002).

3.2.1 CARACTERÍSTICAS

Os sistemas de radar basicamente são constituídos pelos seguintes componentes: um transmissor, um receptor, uma antena e um gravador de dados. O transmissor é utilizado para gerar o sinal de microondas e transmitir a energia para a antena de onde o sinal é emitido em direção da superfície terrestre. O receptor coleta o retorno do sinal dos alvos detectados pela antena, os quais são amplificados e filtrados antes de serem registrados pelo gravador de dados. Segundo Van der Sanden (1997), a posição do alvo imageado é detectado quando se converte o tempo de propagação em distância radial e se estabelece a direção de acordo com o direcionamento da antena.

Sendo um sensor de rádio-frequência os radares imageadores são capazes de detectar características físicas (forma, geometria) e elétricas dos alvos. Dependendo do sistema e a banda utilizada é possível obter vários níveis de penetrabilidade no dossel vegetal, oferecendo capacidade adicional de polarimetria e interferometria. Com relação aos alvos dois tipos de propriedades devem ser considerados: (i) o retorno do sinal é

influenciado pelas propriedades geométricas e dielétricas dos objetos, tais como, umidade do solo, relevo, estrutura folhear, rugosidade da superfície (PARADELLA et al., 2000; ULABY et al., 1982), (ii) segunda propriedade se refere a configuração do sistema (características instrumentais) o qual determina a capacidade de discriminação dos alvos imageados.

Conforme Van der Sanden (1997), o sinal retroespalhado possui como atributos o comprimento de onda (λ), a amplitude e fase.

Igualmente aos sensores ópticos os radares operam com um ou mais bandas, as quais correspondem a um determinado comprimento de onda que são identificados por letras (Figura 3).

Bandas	P	L	S	C	X	K	Q	V	W
Frequência (GHz)	0,3	1,0	3,0	10,0	30,0	100,0			
Comp. de onda (cm)	100	30	10	3	1	0,3			

Figura 3: Espectro de Microondas e a identificação das bandas por letras.

Fonte: Adaptada de Dallemand et al. (1993).

3.2.2 PROPRIEDADES GEOMÉTRICAS

A plataforma que transporta o sensor radar move-se de acordo com a sua órbita (radar orbital) ou direção de voo (radar aerotransportado). A largura do pulso de microondas transmitido possui relação direta com o tamanho da antena utilizada pelo sistema de radar, assim como, a resolução na direção do voo.

A Figura 4 ilustra a direção da linha de voo (em azimute) e a direção ortogonal que é denominada alcance (range).

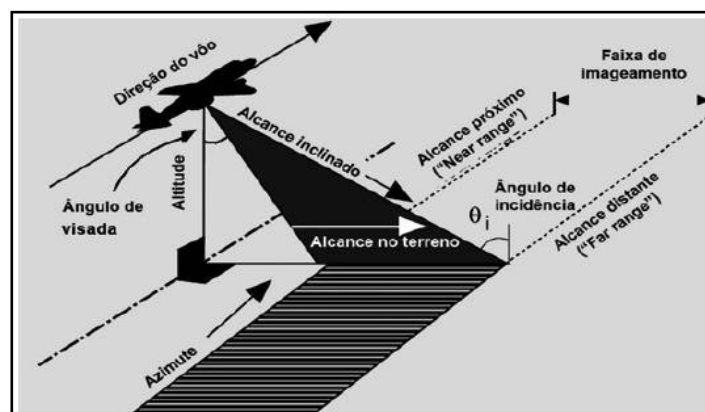


Figura 4: Geometria de aquisição de imagens por radares aerotransportado.

Fonte: Adaptado de Almeida (2008)

Os primeiros radares imageadores eram do tipo radar de abertura real (RAR), trabalhavam com o tamanho efetivo da antena o qual apresentava problemas de resolução espacial limitada na imagens geradas. A fim de aumentar a resolução azimutal do RAR sem a necessidade de se aumentar o tamanho físico da antena, desenvolveu-se o SAR. Segundo [Dobson et al. \(1992\)](#), os radares de abertura sintética (SAR) aproveitam o próprio deslocamento da plataforma para simular, através de combinações de sinais refletidos, uma antena várias vezes maior que o tamanho real afim de melhorar a resolução azimutal.

A relação fundamental entre as características do sistema de radar, o alvo, e do sinal emitido pela antena, o qual interage com a superfície imageada e retorna para a antena foi estabelecida através da seguinte equação, conforme ([ULABY et al., 1986a](#); [LEWIS et al., 1998](#)).

$$P_R = P_T (\sigma^0 A) \left(\frac{G^2 \lambda^2}{(4\pi)^3 R^4} \right) \quad (1)$$

onde a potência do sinal recebido (P_R), é diretamente proporcional à potência do sinal transmitido (P_T), ao coeficiente de retroespalhamento (σ^0), a área efetiva da abertura da antena (A), ao ganho da antena (G), ao comprimento de onda do radar (λ) e a $1/(4\pi)^3 R^4$, onde R é a distância entre o radar e o alvo, considerando a transmissão e a recepção da energia de forma isotrópica. O coeficiente de retroespalhamento (σ^0), que é adimensional, está diretamente relacionado aos parâmetros dos alvos, enquanto que os demais termos da equação do radar se relacionam com os parâmetros do sensor.

Segundo [Leckie e Ranson \(1998\)](#) a interação do sinal emitido por radar em ambiente florestal pode ocorrer de forma variada, dependendo da combinação das respostas geradas pelos diferentes mecanismos de espalhamento ocasionados pela interação do solo, troncos, copa das árvores (Figura 5).




Figura 5: Tipos de Mecanismos de retroespalhamento em ambientes florestais.

- (a) Retroespalhamento superficial e de interior de dossel;
- (b) Retroespalhamento de troncos e galhos;
- (c) Retroespalhamento do solo;
- (d) Reflexão dupla tronco-solo;
- (e) Retroespalhamento integrado entre tronco e solo.

Fonte: Adaptado de [Ulaby et al. \(1984\)](#) e [Kuplich \(2003\)](#)

Os principais fatores que influenciam no comportamento do coeficiente de retroespalhamento são os parâmetros do sistema do sensor e os parâmetros do alvo imageado ([ULABY et al., 1986b](#)), sendo os parâmetros do primeiro constituído pelo comprimento de onda (frequência), a polarização, o ângulo de incidência e o azimute de visada. Os parâmetros do alvo por sua vez estão relacionados às propriedades geométricas e dielétricas que influenciam no retorno do sinal.

3.2.3 PARÂMETROS DO SISTEMA (RADAR)

3.2.3.1 COMPRIMENTO DE ONDA (λ)

A magnitude do coeficiente de retroespalhamento dos alvos está diretamente relacionada ao comprimento de onda, devido esta definir a ordem de grandeza dos efeitos oriundos da rugosidade superficial e constante dielétrica dos alvos ([ULABY et al., 1986a](#); [LEWIS et al., 1998](#)).

O nível de penetração do sinal de microondas em dossel florestal dependerá do comprimento de onda utilizado e das condições dielétricas do alvo ([LE TOAN et al., 1992](#); [KUPLICH, 2003](#)). Os sinais com frequências baixas possuem o maior poder de penetração, e sofrem interferências da constante dielétrica do meio, devido à umidade. A Tabela 1 relaciona os nomes das bandas de radar com seus respectivos comprimentos de ondas e frequência.

Tabela 1: Bandas de Sensores de Radar imageadores.

Banda	λ (cm)	Frequência (GHZ)
X	2,4 a 3,8	8 a 12,5
C	3,8 a 7,5	4 a 8
S	7,5 a 15	2 a 4
L	15 a 30	1 a 2
P	75 a 133	0,2 a 0,4

Fonte: Adaptada de [Jensen \(2000\)](#)

Nos maiores comprimentos de onda, como nas bandas L e P, o pulso emitido pode penetrar no dossel e chegar ao solo dependendo da densidade, estrutura e umidade do meio. Segundo [Kasischke et al \(1997\)](#), [Dobson \(2000\)](#) nestes comprimentos de onda ocorre uma maior interação com os troncos e galhos maiores. As bandas X e C são comumente usadas em estudos aplicados a mapeamento geológico. Com a capacidade de penetrar dosséis de uma floresta as bandas L e P, fornecem dados significativamente uteis para estudos em regiões de floresta tropical.

3.2.3.2 POLARIZAÇÃO

A polarização é definida pelo vetor campo elétrico (E), frequentemente linear e dependendo da orientação da onda de radar, transmitida e recebida, podem gerar diferentes tipos de imagens. Isto permite trabalhar com dados polarizados horizontalmente (H), verticalmente (V) ou com polarização cruzada (HV).

Em sistemas de radar as polarizações são descritas nas seguintes formas:

- HH: transmissão na horizontal e recepção na horizontal;
- VV: transmissão na vertical e recepção na vertical;
- HV: transmissão na horizontal e recepção na vertical;
- VH: transmissão na vertical e recepção na horizontal.

As imagens de radar podem ser geradas por uma única polarização (modo univariado), duas polarização (modo dual) ou ainda com quatro polarizações (modo quad-pol). A polarização univariada ocorre quando o sistema de radar é programado para emitir e receber apenas um tipo de sinal, como exemplo podemos citar a polarização HH. Já uma polarização dual (bivariada) acontece quando duas combinações de sinais transmitidos e recebidos ocorrem, ex: HH, HV. Quando ocorre o imageamento com modo de aquisição programado com quatro combinações de sinais transmitidos e recebidos, neste caso, os dados são do tipo multipolarizados (quad-pol) com polarizações HH,HV,VH,VV (Figura 6).




Figura 6: Modos de imageamento polarimétrico em sistema de radar aerotransportado.
 Fonte: Adaptada de [CCRS \(2009\)](#).

Os primeiros radares imageadores possuíam a capacidade de operar com um único canal e com uma única antena fixa com a finalidade de emitir e receber os sinais de microondas, tal configuração permite registrar os dados em sinal de amplitude recebido pela antena (ex.: componentes V e/ou H). Segundo [Paradella et al. \(2005\)](#), os radares que possuem esta configuração são classificados como radares imageadores não polarimétricos, sendo os mais comuns RADARSAT-1, JERS-1, ERS-1 e ERS-2.

Radares que operam em único canal, não possuem a capacidade de medir as propriedades dos alvos em sua plenitude, que são descritas pelas assinaturas polarimétricas. Tais informações podem ser adquiridas somente utilizando radares multipolarizados, pois transmitem comprimentos de ondas em ambas polarizações H e V, além de registrar as informações de amplitude e de fase do sinal recebido. Dentre os sensores de radar orbital polarimétricos podemos citar: o RADARSAT-2 e ALOS/PALSAR.

3.2.3.3 ÂNGULO DE INCIDÊNCIA (Θ)

A aparência dos objetos em uma imagem de radar é pelo ângulo de incidência (θ_i) utilizado durante o processo de coleta dos dados, pois influencia o retroespalhamento conforme os efeitos da superfície.

O ângulo de incidência é formado pela direção perpendicular à superfície terrestre e o feixe que incide do sinal de onda transmitida (Figura 7). A variação ocorre de acordo com o tipo de terreno imageado. A altitude da plataforma (orbital ou aerotransportada) que o sistema está acoplado gera forte efeito sobre a geometria de imageamento. Os sistemas orbitais normalmente operam em altitudes entre 600-800 km, enquanto os aerotransportados entre 3-12 km.




Figura 7: Relação entre os ângulos de incidência nos sistemas: Aerotransportado (Ângulo de incidência e Ângulo de depressão); Orbital (Ângulo de Visada)

A variação do ângulo de incidência entre os sistemas orbitais e aerotransportados ocorre devido à diferença de altitude a qual eles operam. Portanto, os sistemas em órbita apresentam ângulos de incidências mais acentuados, com cobertura angular que varia entre ($37^\circ - 40^\circ$) enquanto nas aeronaves a variação fica entorno de ($15^\circ - 60^\circ$). A figura 8 ilustra o comparativo entre sensores orbital e aerotransportado.

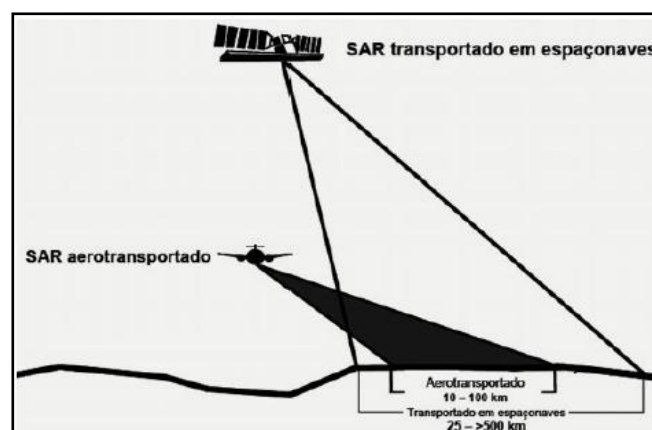


Figura 8. Comparação entre imageamentos orbital e aerotransportado.

Fonte: Adaptado de [CCRS \(2007\)](#).

3.2.3.4 COMPORTAMENTO DOS ALVOS

Segundo [Ulaby et al. \(1982\)](#), as superfícies imageadas são classificadas de acordo com o padrão do retroespalhamento nas seguintes categorias: (i) lisa: quando a superfície reflete a energia incidente de forma especular, com ângulo de reflexão na direção oposta ao ângulo de incidência); (ii) intermediária: energia refletida de forma difusa pela superfície; (iii) rugosa: a energia incidente é retroespalhada em várias direções de forma homogênea (Figura 9).




Figura 9: Modelo de padrões de espalhamento em sistema aerotransportado.
Fonte: Adaptado de [Ulaby et al. \(1982\)](#).

3.2.3.5 CONSTANTE DIELETRICA

Segundo [Lewis \(1998\)](#), a constante dielétrica altera a capacidade do alvo imageado em absorver, refletir e transmitir o sinal na faixa de microondas, devido à forte influência na interação da radiação eletromagnética com a superfície do terreno.

Tal fenômeno em ambientes florestais causa alta refletividade no sinal emitido conforme o teor de umidade contido no dossel, quanto maior o teor de umidade maior será o efeito da constante dielétrica. Medidas de retroespalhamento em áreas de solo exposto úmido e floresta mostraram alta sensibilidade em ângulos de incidência na região do nadir, conforme [Ulaby e Bativala \(1975\)](#).

3.2.4 RUÍDO SPECKLE

Outra característica de imagens de radar é a presença de ruído (*speckle*) inerente de dados adquiridos através da transmissão e recepção de ondas coerentes.

O *speckle* é usualmente considerado como um ruído multiplicativo, sendo mais intenso onde a intensidade do sinal for maior. Nesse modelo multiplicativo, supõe-se que cada pixel da imagem pode ser expresso pela Equação (2), onde o sinal observado é o produto das variáveis aleatórias (independentes) que estão modelando o retroespalhamento e o ruído *speckle*.

$$Z = X.Y \quad (2)$$

onde, Z representa o sinal observado, X representa a variável aleatória que modela o retroespalhamento e Y representa a variável aleatória que modela o ruído *speckle* (SANT'ANNA et al., 2007).

O ruído *speckle* gera uma aparência granular na imagem, pois torna a relação sinal-ruído mais baixa. Isso dificulta o processamento digital através de segmentações e classificações automáticas, bem como a interpretação visual e a extração de informações por intérpretes (SABINS, 1997; SANT'ANNA, 1995). Assim, a redução do ruído *speckle* é necessária para melhorar a classificação das imagens SAR e auxiliar nas interpretações das feições presentes na cena.

A redução do ruído em imagens de radar podem ser efetuada através do processamento *multi-look*, segundo Sant'Anna (1994). Este procedimento consiste no processamento que equivale a redução do tamanho da abertura sintética por um fator que seria o número de visadas (looks) do mesmo pixel. No caso de dados *multi-look* de regiões homogêneas a intensidade terá uma distribuição Gamma. Outra técnica utilizada para a redução do *speckle* consiste na aplicação de filtros digitais.

Os filtros podem ser agrupados em dois grandes grupos: adaptativos e não adaptativos. Os filtros não adaptativos utilizam os parâmetros de toda a imagem de forma conjunta. Esses filtros não consideram as variações provocadas pelo retroespalhamento do terreno e as características do sensor, não sendo indicados para dados SAR.

Os filtros adaptativos modificam as imagens de acordo com as estatísticas obtidas a partir das informações de cada pixel, considerando as especificidades geradas pelas variações do retroespalhamento. A principal vantagem dos filtros adaptativos é que eles mantêm uma estimativa dos valores de retroespalhamento

dentro de regiões homogênea, permitindo uma melhor definição das bordas e preservando a textura das imagens. Esses filtros foram especificamente desenvolvidos para imagens SAR (LOPES et al.,1990).

3.3 CLASSIFICAÇÃO DIGITAL DE IMAGENS

O processo de classificação digital de imagens consiste em uma série de procedimentos para atribuir cada *pixel* de uma imagem a uma classe temática. Essa atribuição é feita com base em observações no *pixel* em si e na sua vizinhança e com base numa série de regras. É um processo que realiza a extração de informações através da definição e reconhecimento de objetos e padrões, sendo amplamente empregada em mapeamentos da superfície terrestre.

De acordo com Crósta (1992), alguns pontos básicos devem ser executados. Primeiro, um conjunto de classes é previamente determinado antes de se iniciar a classificação, classes essas cujas propriedades devem ser bem conhecidas. Segundo, supõe que qualquer *pixel* na imagem pertence necessariamente a uma dessas classes. Terceiro, que as classes podem ser definidas usando algumas propriedades observáveis da cena e não apenas valores de reflectância.

Existem essencialmente dois tipos de classificação: a **classificação supervisionada**, a qual requer uma seleção de amostras por parte do analista, sendo necessário algum tipo de conhecimento prévio da área para que possa haver a definição de classes. Nesse tipo de classificação, as amostras de identidade conhecida são utilizadas como base para classificar pixels de identidade desconhecida (MATHER, 1999). A **classificação não-supervisionada**, é dita não-supervisionada quando não se tem conhecimento prévio das classes de interesse. Neste caso, o classificador decide, com base em regras determinadas, quais as classes presentes e a que classe pertence cada pixel da imagem (JENSEN, 2005).

Dentre os algoritmos de classificação supervisionada podemos destacar o de Máxima Verossimilhança (Maxver) e *Interactive Conditional Mode* (ICM), e o *Support Vector Machine* (SVM).

3.3.1 CLASSIFICAÇÃO MAXVER-ICM

De acordo com [Campbell \(2007\)](#), a classificação por Maxver é um método usualmente empregado na classificação de imagens digitais. O algoritmo Maxver realiza uma classificação supervisionada, pixel a pixel, com baixo custo computacional. Esta classificação é oriunda do método estatístico de Máxima Verossimilhança e considera a ponderação das distâncias entre médias dos níveis de cinza das classes. Entretanto, esse método não considera a dependência espacial entre as classes definidas. O funcionamento da classificação Maxver é baseado nas seguintes etapas: definição das classes temáticas e seleção de amostras para o treinamento do classificador; associação de uma função de distribuição de probabilidade para cada uma das classes definidas; e classificação, pixel a pixel, segundo a classe com maior verossimilhança.

O algoritmo *Interactive Conditional Mode* (ICM) pode ser considerado como um método de refinamento. Esse algoritmo é um classificador pixel a pixel contextual que considera as informações dos pixels vizinhos a partir de uma classificação previa, a qual pode ser, por exemplo, a realizada pelo algoritmo Maxver. A combinação entre os algoritmos Maxver e ICM permite que a imagem, em uma primeira fase, seja classificada por Maxver e, em uma segunda fase, pelo algoritmo ICM, considerando a informação contextual entre os pixels. Assim, a classificação será resultado do valor do pixel observado e das classes atribuídas aos pixels vizinhos ([VIEIRA, 1996](#)).

[Correia \(1998\)](#) e [Vieira \(1996\)](#) empregaram classificações supervisionadas específicas para dados de radar. Nessas abordagens foram considerados os algoritmos Maxver e Maxver-ICM customizados para atender ao ajuste de múltiplas fontes de evidências estatísticas presentes nos dados SAR. Essa mesma metodologia foi posteriormente aplicada sobre dados SAR por [Gaboardi \(2002\)](#), [Silva \(2007\)](#) e [Frery et al. \(2007\)](#), [Aboud Neta et al. \(2009\)](#), [Dutra et al. \(2009\)](#).

3.3.2 CLASSIFICAÇÃO SVM (*SUPPORT VECTOR MACHINE*)

O classificador SVM (*Support Vector Machine*) é um método de classificação de imagens baseado em um algoritmo de otimização que, a partir das amostras de treinamento, define hiperplanos de separação ótimos entre as classes maximizando a margem (distância) entre elas (HAYKIN, 2001). O mapeamento das classes durante a classificação é realizado com base nesses hiperplanos definidos.

Os vetores suporte dos hiperplanos definem a margem de separação das classes e correspondem aos elementos críticos das amostras de treinamento, já que são os pontos que delimitam as superfícies de decisão (VAPNIK, 1995). No algoritmo SVM podem ser empregadas funções simétricas, chamadas funções *kernel*, que satisfazem a algumas condições com o objetivo de produzir superfícies de separação mais complexas.

O algoritmo SVM pode considerar classes linearmente ou não-linearmente separáveis definindo estratégias multiclases (regras um-contra-um ou um-contra-todos). Para o caso de classes não-linearmente separáveis, deve ser inserida uma penalidade no algoritmo de classificação permitindo certa tolerância de erro na definição dos hiperplanos de separação, sendo que uma maior penalidade reduz a tolerância ao erro e conseqüentemente os hiperplanos definidos são menos flexíveis, podendo causar problemas de generalização na classificação.

Classificadores SVM possuem essencialmente técnicas de classificação binárias. Assim, quando o problema de classificação possui mais de duas classes pode-se utilizar estratégias que permitam esta classificação como: one-against-one (1 contra 1) e one-against-all (1 contra todos). A estratégia um contra um constrói uma máquina para cada par de classes. O número de máquinas é obtido através da fórmula $N(N-1)/2$, onde N é o número de classes (GIDUDU, 2007).

Theodoridis e Koutroumbas (2006) abordam as formulações e as considerações necessárias aos algoritmos SVM para classes linearmente e não-linearmente separáveis.

O entendimento matemático deste método pode ser aprofundado nos trabalhos de Vapnik (1995) e Haykin (2001).

3.4 AVALIAÇÕES DAS CLASSIFICAÇÕES

Para uma classificação ser confiável, deve-se efetuar a análise de acurácia da classificação. Em sensoriamento remoto o termo acurácia é tipicamente usado pra expressar o grau de exatidão de uma classificação (LILLESSAND E KIEFER, 1994).

Realizadas as classificações, a avaliação delas é feita com base na análise da exatidão (acurácia) dos resultados gerados. De acordo com Congalton e Green (1999), uma das formas mais eficientes de representar a exatidão de uma classificação é por meio de uma matriz de erro ou confusão, que descreve os resultados obtidos com a classificação realizada comparando-os com dados de referência. A partir dessas comparações podem ser calculados erros de inclusão e omissão, exatidões do produtor e do usuário, além de outras medidas de exatidão como a exatidão ou acurácia global e o coeficiente de concordância *Kappa*.

Shimabukuro (1996), cita que a partir da matriz de erros pode-se determinar a exatidão da classificação por meio de técnicas analíticas e de técnicas descritivas. A técnica descritiva “exatidão global” a mais usual, e sua obtenção é a partir da divisão da soma do número de pixels nas amostras classificadas corretamente (diagonal principal) pelo número total de pixels das amostras de treinamento. Dentre os métodos disponíveis o mais conhecido e utilizado é a análise através do índice *Kappa*.

Esse índice é uma técnica empregada para avaliar a exatidão do mapeamento através da elaboração de uma matriz de confusão, também conhecida como matriz de erro.

De acordo com Brites et al. (1996), esse índice é recomendado como uma medida apropriada para avaliar a exatidão porque representa inteiramente a matriz de confusão, sendo esta uma forma padronizada para reportar erros de classificações. A matriz de erro é construída comparando os resultados obtidos nas diferentes classes com um mapa de referência ou verdade terrestre que reporta as mesmas classes consideradas. A matriz de confusão define os erros de inclusão (erros de comissão) e os erros de exclusão (erros de omissão) existentes na classificação (CONGALTON; GREEN, 2009; TREITZ; ROGAN, 2004). A matriz de confusão ainda possibilita o cálculo da precisão por classe temática, além da exatidão global obtida pela classificação.

Os valores obtidos pelo coeficiente de concordância podem ser comparados a tabelas de referência (TABELA 4), obtida empiricamente, gerando valores qualitativos.

Esses critérios relacionam os valores obtidos pelos intervalos do Coeficiente Kappa com a qualidade das classificações (LANDIS e KOCH, 1977).

TABELA 2 – Conceitos das classificações baseados no coeficiente *Kappa*.

Kappa	Conceito
$K < 0$	Péssimo
$0 < K < 0,2$	Ruim
$0,2 < K < 0,4$	Razoável
$0,4 < K < 0,6$	Bom
$0,6 < K < 0,8$	Muito Bom
$0,8 < K < 1$	Excelente

Fonte: Landis e Koch (1977).

3.5 O SENSOR SAR-R99B

O sistema SAR R99-B é um sensor radar aerotransportado que se encontra instalado nas três plataformas R99B (aeronaves modelo Embraer 145 adaptadas) operadas pela Força Aérea Brasileira (FAB). O sistema permite a obtenção de informações sobre as características geométricas e elétricas dos alvos terrestres. No Brasil, o sensor entrou em funcionamento em 2003, nas atividades operacionais do Sistema de Proteção da Amazônia (Sipam). Além do dados em amplitude multipolarizados, o SAR-R99B oferece capacidades adicionais de polarimetria e da interferometria SAR.

3.5.1 CARACTERÍSTICAS

O sistema SAR-R99B opera na banda espectral L (1,27 GHz de frequência e 23,9 cm de comprimento de onda), com dados polarimétricos, ou seja, envia e recebe radiação eletromagnética nas polarizações vertical, horizontal e cruzada (HH, VV, HV e VH), e na banda X (frequência de 9,69 GHz e comprimento de onda em torno de 3,1 cm) com uma única polarização (HH). Permite obter imagens em três resoluções espaciais distintas: 3, 6 e 18 metros com faixas apresentando larguras que variam de 10 a 120 km.

Em síntese, o referido sistema suporta missões de vigilância, mapeamento ou missões híbridas de vigilância/mapeamento. O sistema dispõe de 13 modos para o imageamento SAR, os quais permitem configurações de coleta com resoluções espaciais distintas, resultando em 25 formas de aquisição de dados. As imagens podem ser adquiridas em single-look e multilook, com projeção slant ou ground range (Figura 10).




Figura 10. Modo de mapeamento do Sensor SAR-R99B.

Os dados SAR-R99B são provenientes de três modos de operação distintos: a) Modo de mapeamento nas bandas X e L (Stripmap SAR); b) Modo de vigilância aérea e de superfície com a banda X (SpotSAR, A2A e WAS); e Modo de interferometria (INSAR), (Congar, 2004).

O modo mais comum de operação para obtenção de informações é o Stripmap ou modo de mapeamento, que por sua vez permite várias opções de aquisição de imagens (Quad L + Single X; Dual L + Single X; Dual L + Single X; InSAR + Single L; Quad L, Single L + Single X e InSAR + Quad L).

Na opção Dual L + Single X serão adquiridas duas imagens na banda L (LHH, LVV) e uma imagem simples na banda X (XHH), (Tabela 2).

TABELA 3. Características do Sensor SAR-R99B.

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, LvV, LvH, LhV Banda X = Xhh
Duração do pulso transmitido (τ_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. Vide Tabela Modos de Operação, PRI, Ciclo de Trabalho, Potência e Frequência de operação do SAR
Ângulo de incidência (graus)	Varia de 36,34° a 84,23°
Modos de aquisição	Varia em função do Modo de Operação do Sensor SAR
Resolução radiométrica (db)	Informação não disponível
Resolução em alcance (m) - "slant range resolution"	Varia em função do Modo de Operação do Sensor SAR
Resolução em azimute (m) - "slant range resolution"	Varia em função do Modo de Operação do Sensor SAR
Número de visadas "looks"	3 metros = 4 looks 6 metros = 8 looks 18 metros = 16 looks
Largura da faixa (Km) "Swath width"	Variável de podendo ser de 12 km, 20 km, 40 km, 60 km, 120 km
Resolução horizontal (m)	Basta utilizar a geometria de coleta para calcular a resolução em "ground range".
Altura de vôo (m)	Pode ser escolhida entre 30,000 e 37,000 (9.149 a 11.277 metros) acima do Nivel Médio do Mar
Velocidade da plataforma (m/s)	Pode ser escolhida entre 330 nós (115 m/s) e 390 nós (195 m/s)
Sistema de Posicionamento	INS/GPS (erro esférico provável = 76 metros)

Para sistemas imageadores que operam na faixa das microondas, a capacidade de prover imagens de elevada resolução espacial independe das condições atmosféricas e da existência da fonte solar de radiação (HENDERSON e LEWIS, 1998), o que os torna de elevada importância para obtenção de imagens em regiões como a Amazônia, onde a presença de chuva, nuvens, e fumaça impõem graves restrições à utilização de sensores ópticos (PARADELA *et. al.*, 2005).

Outro aspecto altamente relevante envolve a sua capacidade de penetrar a radiação microondas nos dosséis da floresta. O radar SAR-R99B se difere de radares conhecidos (ERS-1, JERS-1, RADARSAT-1, ERS- 2, SAREX) pela sua capacidade de medir as propriedades de polarização dos objetos através de assinaturas polarimétricas geradas pela transmissão de ondas em duas polarizações (H e V), portanto o sistema é dito polarimétrico. Além disso, mantém as características de registrar a amplitude e a fase do sinal recebido.

A interferometria (modo INSAR) é outra característica diferencial do sistema SAR-R99B. Focado na extração da elevação com dados SAR, o modo INSAR combina imagens complexas adquiridas com defasagem no tempo de emissão e recepção. Assim, as diferenças em fase entre as imagens obtidas são utilizadas para gerar a topografia do terreno (Raytheon Company, 1998). A imagem obtida resulta em um Modelo Digital de Elevação (MDE), que por sua vez expressa as componentes altimétricas do terreno. Como exemplo de geração de MDE interferométrico pode-se citar a missão orbital do SRTM (Shuttle Radar Topography Mission) da NASA (Paradela *et.al.*, 2005).

3.6. USO E APLICAÇÃO DE DADOS SAR

O surgimento e a disponibilidade de dados de radar nas últimas duas décadas, possibilitou uma quantidade significativa de projetos de pesquisa voltados à investigar o potencial das imagens de radar, e com isso, gerar informações no campo científico com estudos voltados para o monitoramento da cobertura terrestre, com ênfase na discriminação de classes de uso e cobertura da terra, e detecção de mudança de cobertura ao longo do tempo.

De uma forma geral, as pesquisas realizadas fizeram uso de diferentes técnicas de extração automática utilizando bandas com comprimento de ondas distintos (banda X, L, C e P) com intuito de gerar informações para detecção de áreas afetadas por fogo, detecção de desmatamento, monitoramento de uso de cobertura da terra, mapeamento de tipos de florestais, entre outros. Nesta seção serão apresentados os trabalhos realizados conforme levantamento literário pertinente a esta pesquisa.

Com o objetivo de discriminar áreas desflorestadas e estágios de regeneração em floresta tropical através da aplicação de dados SIR-C (Quad C e Quad L) [Rignot et al. \(1997\)](#) fez uso de classificador estatístico supervisionado, o qual apresentou resultado significativos em áreas desflorestadas num período menor de que 12 meses, a partir de dados coletado em banda L. Conforme [Almeida Filho et al. \(2007\)](#) a detecção de áreas desflorestadas é facilmente identificadas devido à alta resposta de sinal em banda L quando se faz o uso da polarização HH durante a análise.

De acordo com [Saatchi et al. \(1997\)](#) o classificador de Máxima Verossimilhança (MAXVER) foi utilizado para mapeamento de cobertura de solo utilizando dados SIR-C (banda C HH, HV e banda L HH, HV). Conforme os resultados obtidos a detecção de áreas degradadas em ambiente florestal ocorreu devido à sensibilidade da polarização HV da banda L ao sinal resultante da interação solo-tronco. Tal fato é resultante da sensibilidade da polarização que cria um alto nível de contraste ocasionado pelo espalhamento volumétrico, que ocorre na copa das árvores assim como o baixo retorno do sinal em áreas de solo exposto ou áreas com vegetação baixa.

[Shimabukuro et al. \(1998\)](#) analisaram dados multitemporais RADARSAT através de técnicas de componentes principais e classificadores MAXVER (Máxima Verossimilhança) e ICM (Iterated Conditional Modes) para mapeamento de tipos florestais na região da Floresta Nacional do Tapajós – PA. O resultado obtido mostrou

uma boa concordância das classes mapeadas com o mapa de vegetação produzido pelo projeto RADAM. Neste trabalho os autores ressaltam que os dados multitemporais do RADARSAT proporcionaram fácil identificação das áreas recém desflorestadas a partir de análise visual.

Van Der Sanden e Hoekman (1999), aplicaram classificação estatística supervisionada em dados polarimétricos AIRSAR (Banda C, Banda L e Banda P) para mapeamento de floresta, desflorestamento e corte seletivo. O conjunto de três canais de dados (C-LL + P-HV + P-Potencial total) proporcionou como resultado uma boa acurácia das áreas de floresta secundária, desflorestamento e as de corte seletivo. Os autores ressaltam que a diferença de fase entre as polarizações HH e VV não contribuíram de forma significativa para a discriminação das classes investigadas.

O projeto GRFM (Global Rain Forest Mapping) realizou diversos estudos sobre classificação de imagens JERS-1 para mapeamento de uso e cobertura de solo em regiões de florestas tropicais (Rosenqvist *et al.*, 2000, Milne *et al.*, 2002; Podest e Saatchi, 2002).

Saatchi *et al.* (2000) utilizou classificadores bayesiano MAP (Máximo a posteriori) e classificadores por regras de decisão e atributos de textura para estudo de mapeamento de classes da terra, na região amazônica, em imagens JERS-1. Pesquisa similar foi realizada por Simard *et al.* (2000) na região do Gabão, África.

Com intuito de avaliar dados SAR polarimétricos duais (duas polarizações) e monopolarizados (uma polarização) para discriminar classes de cobertura florestal, Lee *et al.* (2001) empregou o classificador de Máxima Verossimilhança (MAXVER) com base na distribuição de Wishart, a metodologia empregada proporcionou um mapeamento com nível de acurácia satisfatório a partir de dados polarimétricos das bandas L e P. O resultado alcançado com o par de polarizações HH e HV da banda L foram tão satisfatório em relação ao resultado obtido através do uso de quatro polarizações (modo Quad L).

Touzi *et al.* (2004) utilizaram dados polarimétricos simulados a partir do sensor Radarsat 2 para caracterizar classes de floresta temperada no Canadá. O melhor resultado da caracterização dos tipos das classes de interesse foram obtidos com os dados em polarização circular e o atributo polarimétrico obtido através do ângulo alfa médio. Goodenough *et al.* (2006) analisou dados simulados do Radarsat 2 onde aplicou o classificador polarimétrico Wishart K-médias H/α (POTTIER e LEE, 1999)

para detecção feições oriundas de incêndio florestal.

Algoritmos de segmentação multiresolução e de classificação não supervisionada (THIEL *et al.*, 2006) foram aplicados à dados do JERS-1 para mapeamento de áreas desflorestas, a acurácia do resultado foi obtida através da concordância com o mapa de desflorestamento gerados a partir de imagens ópticas (Landsat TM), a pesquisa destaca a importância da correção radiométrica para fim de discriminação de classes de cobertura do solo.

Freitas *et al.* (2008) analisaram dados polarimétricos da banda P através de classificadores de Máxima Verossimilhança (MAXVER) juntamente com evidências estatísticas (FRERY *et al.*, 2007) e classificador ICM (Iterated Conditional Modes) para mapear classes de cobertura do solo no estado do Pará, região da Floresta Nacional de Tapajós. Conforme resultado, os conjuntos de dados em intensidade que apresentaram melhores resultados foram das polarizações HH+VV e HH+HV+VV, o trabalho ressalta que a aplicação do uso da distribuição mais adequada contribuiu significativamente no resultado das classificações realizadas em pares de intensidade.

Aboud Neta *et al.* (2009) constataram que com a utilização de polarização dual, foi possível obter uma melhoria na classificação de uso e cobertura da terra em comparação com polarização HH do sensor JERS-1. As regiões de interesse foram melhor classificadas devido a combinação de dois canais formando os pares das polarizações {HH ,HV} e {HV,VV}. Tal combinação contribuiu na diminuição do erro de classificação.

Aboud Neta *et al.* (2009) verificaram que a polarização dual {HV e VV} produziu resultado significativo para mapeamento florestal com as classes: floresta primária, secundária, solo exposto, agricultura, floresta degradadas, pasto e pasto sujo. Dutra *et al.* (2009) obtiveram melhor resultado com a combinação obtidas pelos canais HH+HV, sendo que o valor de acurácia global não foi satisfatório.

Segundo Hoekman e Quiñones (2002), os resultados mais promissores na discriminação de padrões de uso e cobertura do solo, incluindo desflorestamento, foram obtidos através de imagens polarimétricas e multipolarizadas com combinações de diferentes frequências.

A capacidade de dados SAR polarimétricos em fornecer maior quantidade de informação a respeito da superfície, tem proporcionado avanços significativos no campo da pesquisa de radar (LEE e GRUNES, 1992; VAN DER SANDEN e HOEKMAN,

ZALOTI *et al.*, 2006).

4 MATERIAIS E MÉTODO

Neste capítulo são apresentados os materiais utilizados e a metodologia aplicada neste estudo. De modo específico são descritos a área de estudo, os dados empregados, os programas (softwares) e o hardware.

4.1 ÁREA DE ESTUDO

A área de estudo deste trabalho está situada na região do km 20 da BR-174 no município de Manaus no Estado do Amazonas, entre os pares de coordenadas S $02^{\circ} 54'$, W $60^{\circ} 5' 24''$ e S $2^{\circ} 48' 21''$, $60^{\circ} 0' 57''$ que compreende uma região de aproximadamente 87 km^2 (Figura 11). Os fatores determinantes na escolha da região para a realização da presente dissertação foram a diversidade das classes de uso e da terra existentes, como: floresta primária, agricultura, solo exposto e vegetação secundária em diferentes estágios de regeneração e a disponibilidade de imagens do sensor SAR R99-B.




Figura 11. Localização geográfica da área de estudo.

Em destaque é ilustrado a área de estudo com a imagem SAR R99-B de 20/05/2009 (composição VV(R)HV(G)HH(B)).

4.1.1. CLIMA

Conforme sua posição geográfica, a região de Manaus encontra-se na faixa de domínio tropical, característicos de grande parte do Brasil, sendo marcada por duas estações que podem ser diferenciadas quanto ao nível de precipitação.

Apresenta pluviosidade anual na ordem de 2100 mm, com uma estação seca que ocorre no período de junho a outubro e a estação chuvosa entre novembro e maio, apresenta níveis de precipitações anuais mínimas em torno de 50 mm no mês de agosto, e máximas entorno de 300 mm no mês de março. Segundo a classificação de Köppen, a região esta inserida no grupo A (clima tropical chuvoso) dos tipos Af e Amw. As temperatura médias mensais variam entre 24 e 28° C com umidade relativa do ar sempre elevada, com medias variando entre 77% na estação seca, e 88% na estação chuvosa (LUCAS, 1989).

A precipitação pluvial na região causa efeito direto no comportamento das drenagens existentes, pois observa-se que a partir do mês de outubro o nível de água nos cursos d'água volta a se recuperar, atingindo o nível normal durante o mês de dezembro. O período da “cheia”, como assim é conhecido, corresponde aos meses entre janeiro e maio, sendo caracterizado pelo aumento excessivo do nível d'água, atingindo amplitude superiores a 10m em relação a época da estiagem.

4.1.2. SOLO E RELEVO

Segundo Ranzani (1980), os tipos de solo predominante na região são do tipo latossolos amarelos álicos e podzólicos vermelho-amarelo.

A região contém porções do Planalto Dissecado Rio Trombetas-Rio Negro e da Planície Amazônica. As cotas topográficas oscilam entre 120 e 170m ao longo da rodovia AM-010 que liga a cidade de Manaus ao município de Itacoatiara, sendo que as menores cotas registradas são 80m localizadas no vale do rio Preto da Eva e de 60m nas margens do rio Urubu (NASCIMENTO *et al.* 1976; COSTA *et al.* 1978).

O relevo é composto por tabuleiros com extensões que variam de 1 a 9 km e altitudes que oscilam entre 40 e 160m. Na região que compreende a cidade de Manaus, as áreas mais elevadas apresentam cotas topográficas em torno de 100 m, devido o nível topográfico essas áreas são chamadas de “terra firme” por estarem acima do nível atingido pelos rios durante o período de cheia (SOUZA e MEDEIROS, 1972).

4.1.3. VEGETAÇÃO

A vegetação predominante na região é do tipo Floresta Ombrófila Densa. Conforme o sistema de classificação do [IBGE \(1992\)](#), este tipo de floresta é denominado como sendo floresta de *terra firme* e se caracteriza pela sua exuberância, com predomínio de árvores de grande porte. Encontra-se em platôs ou encostas com solos argilosos, segundo [\(NELSON e OLIVEIRA, 1999\)](#) apresentam alta diversidade e baixa similaridade florística entre parcelas próximas.

No município de Manaus, além da floresta primária conservada em muitas áreas, existem dois tipos distintos de florestas secundárias. A primeira apresenta espécies dos gêneros *Vismia*, *Miconia* e *Bellucia*, enquanto *Cecropia* e *Paraumi* representam as espécies no segundo tipo de floresta. Conforme [Lucas et al. \(1989\)](#), à medida que as florestas do primeiro tipo envelhecem, as espécies *Cecropia* e *Paraumi* diminuem e uma floresta mais diversificada se estabelece, composta principalmente de espécies florestais primárias e secundárias.

A área em estudo possui em sua porção leste a rodovia BR-174, que liga Manaus ao município de Presidente Figueiredo e a cidade de Boa Vista no estado de Roraima. Nas últimas décadas, a paisagem nesta região tem sofrido modificações significativas por meio de ações antrópicas.

Devido à região apresentar um mosaico paisagístico, composto por uma diversidade de classes de uso e ocupação do solo e áreas de vegetação em diversos estágios de regeneração, e ao mesmo tempo havendo a disponibilidade de imagens SAR-R99B, tais possibilidades contribuíram para que esta área fosse escolhida para a realização de tal estudo.

4.2 MATERIAIS UTILIZADOS

4.2.1. IMAGENS SAR-R99B

Foram utilizadas imagens do sensor SAR-R99B, com modo de imageamento programado para coleta de dados em banda L (1,28 GHz) com quatro (4) polarizações distintas (HH, HV, VH e VV), com resolução espacial de 3 (três) metros. As imagens foram coletadas no dia 20 de Maio de 2009. (Tabela 5) Figura 12. As imagens foram fornecidas pelo Sistema de Proteção da Amazônia (SIPAM) através da Divisão de Sensoriamento Remoto do Centro Regional de Manaus.

TABELA 4 – Características da imagem em modo de operação.

Características do Imageamento SAR	
Data da Coleta	20/5/2009
Modo de Imageamento	Quad L + X
Polarizações	HH, HV, VV, VH
Tipo de Dado	Unsigned 16 bits
Número de Looks	4 Looks
Resolução da Imagem	3 metros
Tamanho do Pixel	2,5 metros
Números de Segmentos	4 segmentos
Sistema de Coordenadas: Geográfica	Lat/Long
Datum (Sistema Geodésico)	WGS-84
Largura da Faixa Imageada	10 Km
Ângulo de Incidência	36° - 83°
Altitude de Voo	37.000 pés = 11.000 n
Sentido de Voo	L - O, O - L




Figura 12. Modo de coleta das imagens SAR, o desenho da aeronave representa a posição do sensor em relação a área imageada (blocos em verde), direção de voo Leste a Oeste, região de Manaus.

As imagens geradas para a realização deste estudo estão representadas em Amplitude (A), os procedimentos de processamento digital adotado foram efetuados na imagem referente ao fragmento do Segmento 14, como ilustram as Figura 13 e 14.

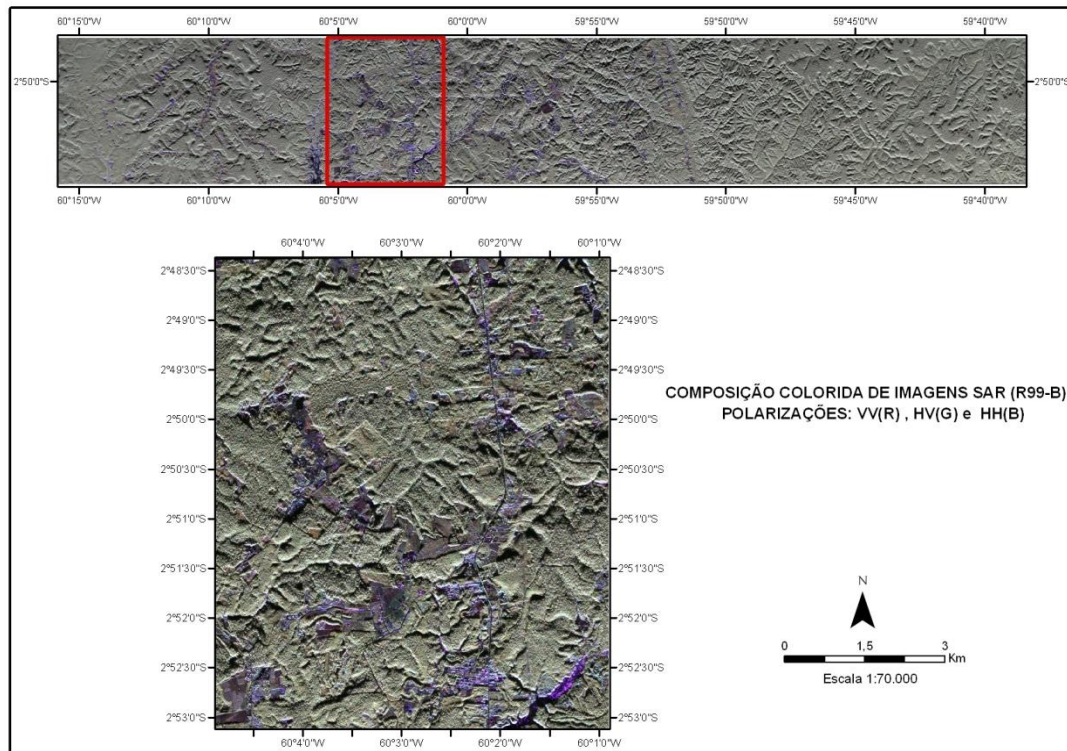


Figura 13. Disposição da área teste (polígono vermelho) na faixa imageada, em destaque a região da imagem onde foram realizados os procedimentos digitais.




Figura 14. Imagens SAR-R99B da área de estudo:
(a) amplitude VV, (b) amplitude VH, (c) amplitude HV, (d) amplitude HH e
(e) composição colorida com as amplitudes R(VV)G(HV)B(HH).

4.2.2. APLICATIVOS E HARDWARE UTILIZADOS

Para o desenvolvimento deste trabalho foram utilizados os seguintes aplicativos e hardware:

- Envi 4.5;
- Classificador Polarimétrico 0.7;

O aplicativo Envi 4.7 foi utilizado para a realização dos procedimentos efetuados durante o processamento digital das imagens em amplitude e classificação *Support Vector Machine* (SVM). O Classificador Polarimétrico 0.7 (CORREIA, 1998; VIEIRA, 1996) foi utilizado durante as classificações com classificador MAXVER-ICM.

Todos os processamentos foram realizados em um microcomputador com processador Intel Centrino Core2 Duo, com velocidade de processamento de 2.3 GHz, memória RAM de 3 GBytes, com capacidade de armazenamento de 120GB e sistema operacional Windows XP.

4.2.3. DADOS AUXILIARES

4.2.3.1. DADOS PLUVIOMÉTRICOS

Segundo Ulaby *et al* (1986a), a ocorrência de elevados índices de precipitação pluviométrica em regiões de florestas tropical eleva a concentração de umidade dos alvos imageados e podem influenciar no processo de interpretação e discriminação de alvos em imagens de radar.

Portanto, utilizou-se como informação complementar dados pluviométricos provenientes de posto de coleta de dados (PCD) localizado o mais próximo da área de estudo, tais dados foram disponibilizados pelo Instituto Nacional de Meteorologia – INMET.

Os dados utilizados referem-se ao mês de Maio do ano de 2009, onde no dia 20 do referido mês foi realizado o imageamento.

A precipitação acumulada foi registrada na estação pluviométrica identificada como 82331-Manaus, localizada nas coordenadas de latitude -3.1292 e longitude -59.9483 no município de Manaus com distancia aproximada em 27km ao sul do centro da área de estudo.

Os volume de precipitação acumulada na região no mês de Maio de 2009 foi estimado em aproximadamente 112 mm, sendo que o valor acumulado nas

ultimas 24 horas que antecederam o imageamento , em 20 de Maio de 2009, foi de aproximadamente 6 mm e com umidade relativa do ar em torno de 78%, Figuras 15 e 16.

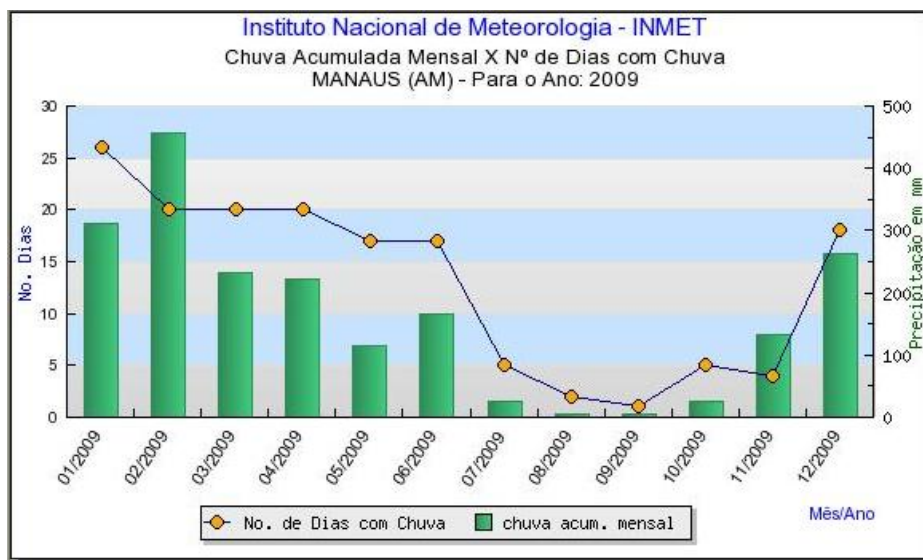


Figura 15. Gráfico representativo de precipitação pluviométrica mensal do ano 2009.

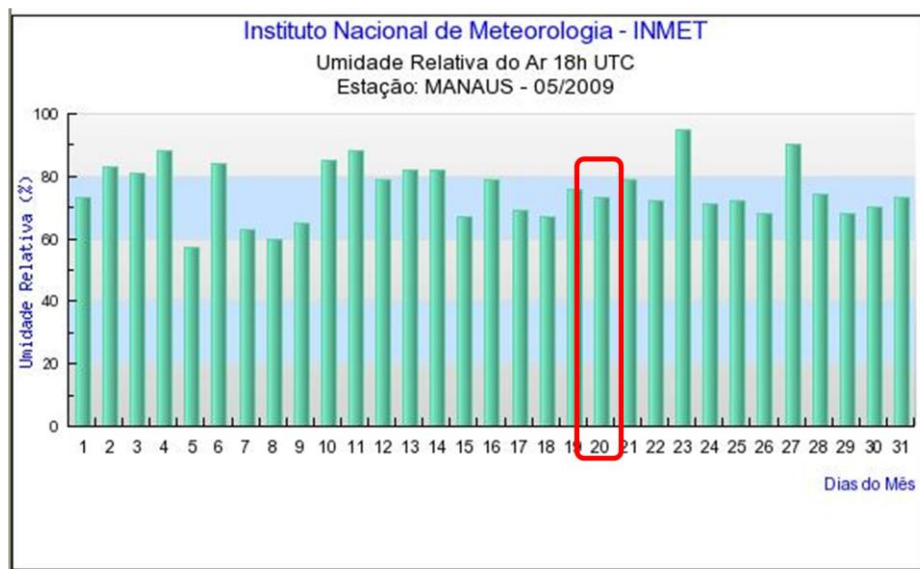


Figura 16. Gráfico dos valores diários da umidade relativa do ar para o mês de Maio de 2009. Em destaque informação referente ao dia que foi efetuada a coleta da imagem.

4.3. METODOLOGIA

Os procedimentos metodológicos executados nesta pesquisa estão ilustrados no fluxograma da Figura 17, os detalhes da metodologia empregada estão descritos nas seções a seguir e organizados de conforme os objetivos específicos propostos.

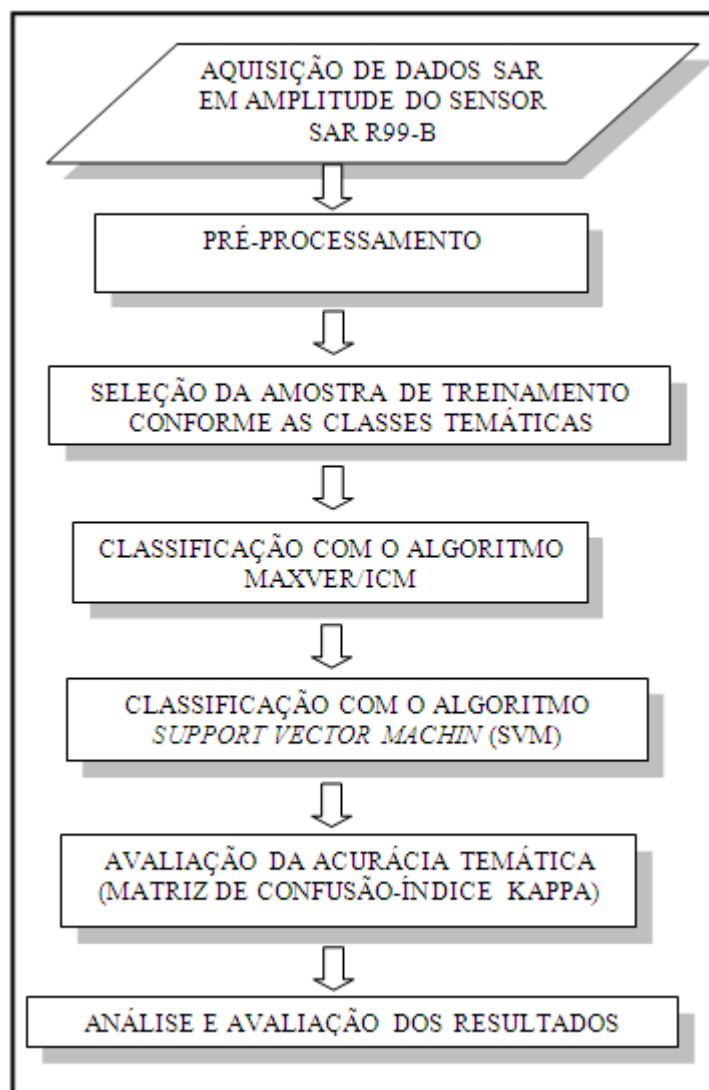


Figura 17. Fluxograma da metodologia geral do trabalho.

4.3.1 PRÉ-PROCESSAMENTO

A primeira etapa da metodologia executada correspondeu aos procedimentos de pré-processamento das polarizações da imagem do sensor SAR-R99B coletada em 20 de Maio de 2009. Entre os procedimentos realizados estão: seleção e recorte da área de estudo, registro da imagem; média dos pixels em azimute (com o objetivo de verificar a necessidade ou não de calibração do padrão de antena); e correção de ruído nas imagens através do uso de filtro *Gamma* com janela de 3x3 pixels.

A figura 18 apresenta a sequência dos procedimentos realizados nesta etapa da metodologia.

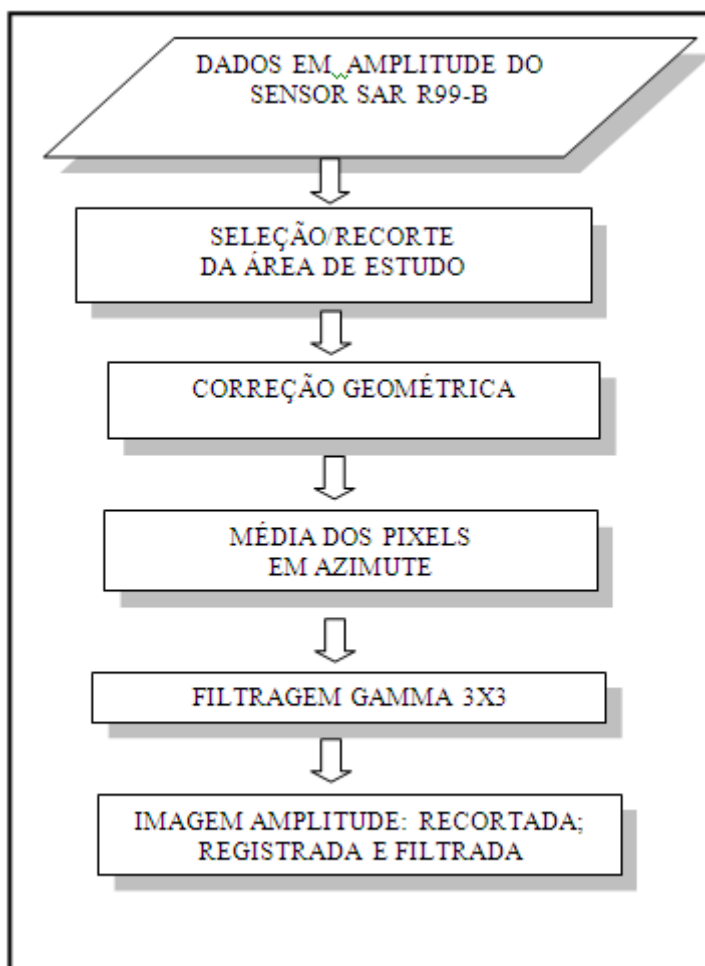


Figura 18. Fluxograma da sequência dos procedimentos realizados no pré-processamento dos dados SAR-R99B.

De posse das imagens em amplitude SAR-R99B, foi realizada a seleção e o recorte da área de estudo obtendo-se uma imagem com dimensões de 727 linhas por 841 colunas. O recorte foi realizado, após análise visual, tendo como base a diversidade de classes de ocupação do solo existentes na área assim como o fácil acesso para fins de atividades de campo.

4.3.1.1 CORREÇÃO GEOMÉTRICA

Dados de sensoriamento remoto estão sujeitos a uma série de distorções geométricas e variação de resolução espacial, não possuindo precisão cartográfica quanto ao posicionamento dos objetos, superfície ou fenômenos nelas representados (Crósta, 1992).

As principais fontes destas distorções geométricas são oriundas de erros internos, causados por distorções referentes ao sensor e os erros externos condicionados aos efeitos da plataforma e das condições de imageamento. Essas distorções geométricas não permitem que sejam realizadas, na ausência de correção, medidas precisas referente ao posicionamento de alvos (Sassagawa, 1999).

Segundo Crósta (1992), Shimabukuro *et al.* (1998 apud Sassagawa, 1999) e Eastman (1998), o processo de correção geométrica envolve as seguintes etapas: (1) a determinação da relação de ajuste polinomial entre o sistema de coordenadas de referência e da imagem a ser corrigida; (2) aplicação do ajuste polinomial para criar a nova imagem, cujos pixels estarão organizados em linhas não horizontais, e (3) interpolação ou reamostragem, dos novos valores de que precisam ser organizados em linhas horizontais.

As imagens coletadas através do sensor aerotransportado SAR-R99B segundo Borges *et al.* (2007) apresentam erro estimado na ordem de 75m entre segmentos coletados. Isto se deve principalmente às características de sensores acoplados em aeronaves.

Com intuito de realizar o registro, das imagens SAR-R99B com 3 metros de resolução espacial, fez-se uso de pontos de controle coletados com DGPS (Diferencial *Global Positioning System*) durante a etapa de campo. Foram coletados no total 8 pontos de controle conforme Figura 19. Para este processamento as imagens foram recortadas, registradas com base nos pontos coletados através de polinômio de 1ª ordem, onde se obteve um erro (RMS) de 0.16, e foram posteriormente projetadas para o sistema de coordenadas Geográfica Lat/Long com Datum WGS84.




Figura 19. Distribuição espacial dos pontos de controle coletados em campo.

4.3.1.2 CORREÇÃO DE PADRÃO DE ANTENA

O “efeito do padrão de antena” ocorre devido à variação do ângulo de incidência entre o *Near Range* e *Far Range*, sendo esse aumento do ângulo proporcional ao aumento da distância entre o sensor e o alvo imageado, ocasionando uma distorção gradual na iluminação da imagem na direção de *Range*. Segundo [Morais \(1998\)](#), esse tipo de efeito é mais intenso em imagens aerotransportadas.

A calibração radiométrica objetiva a correção do segmento selecionado conforme o padrão de ganho utilizado no processamento, reduzindo, desta forma, a influência da variação do ângulo de incidência do retroespalhamento dos alvos ocorrido durante o imageamento. Segundo [Mura et al. \(2007\)](#), esta técnica possibilita uma homogeneização do brilho da imagem no sentido do alcance.

O processo de calibração possibilita a extração de

informações qualitativas e quantitativas das imagens SAR. Tal procedimento é a base para comparação entre conjuntos de dados diferentes. A calibração de imagens polarimétricas, dependendo das aplicações, engloba a fase de calibração radiométrica (correção do padrão de antena), (MURA *et al.*, 2007 e GRAY *et al.*, 1990).

A Figura 20 apresenta a média dos *pixels* ao longo do azimute para um dado range referente à polarização VV da imagem SAR-R99B utilizada neste trabalho. Para construção do gráfico, utilizou-se do recorte da imagem em amplitude da área de estudo no qual foram coletadas as amostras, via criação de polígonos, de áreas homogêneas (ex.: área de floresta primária) ao longo de toda a direção de alcance da imagens. A partir das amostras, determinaram-se os padrões de variação de brilho na direção de alcance, os quais foram ajustados ao polinômio de 5º grau.

De acordo com Figura 20 é possível verificar uma significativa variação entre os dados de resposta radiométrica na componente (polarização VV). Tal informação indica variações no ângulo de incidência na imagem, sinalizando a existência de uma distorção gradual na iluminação da cena. Portanto, fez-se necessário o procedimento de correção do padrão de antena.

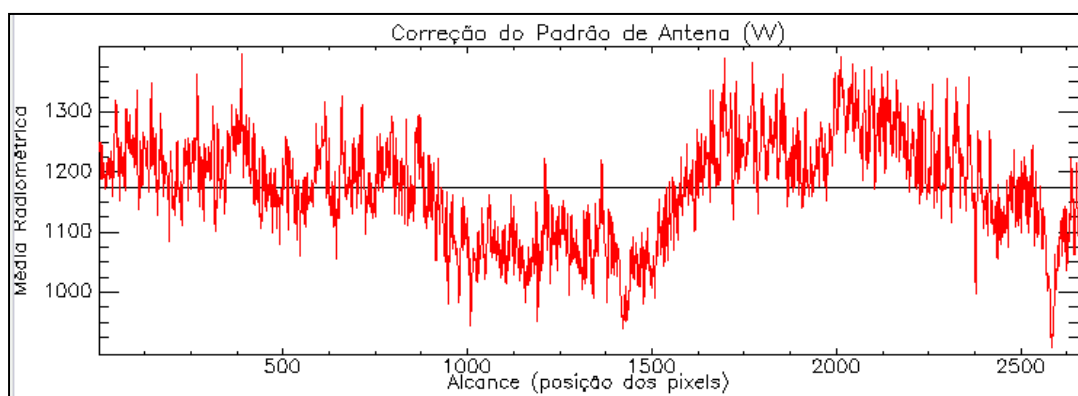


Figura20. Correção do Padrão de Antena (*range*).

4.3.1.3 FILTRAGEM DO RUÍDO (*SPECKLE*)

Imagens de radar apresentam ruído característico conhecido como *speckle*. O *speckle* é usualmente considerado com um ruído multiplicativo, sendo mais intenso onde o sinal de retorno do retroespalhamento for maior. Com isso gera uma aparência granular na imagem dificultando o processamento digital efetuado através de técnicas de segmentação e classificação automática, bem como a interpretação visual e a extração de informações pelo interprete (SABINS, 1997; SANT'ANNA, 1995).

Após a correção radiométrica das imagens o procedimento seguinte foi realizar a filtragem das imagens utilizando o filtro adaptativo *Gamma* com janela de 3x3 pixels com intuito de comparar posteriormente o desempenho dos resultados das classificações entre imagens filtradas (Figura 21) e as não filtradas. O resultado desta etapa da pesquisa permitirá o cumprimento do segundo objetivo específico proposto neste trabalho.




Figura 21. Recorte da área de estudo: Dados SAR-R99B de 20 de Maio de 2009 em amplitude, corrigidos geométricamente, registrados e filtrados com *Gamma* 3x3: filtradas: (a) polarização VV, (b) polarização VH, (c) polarização HV, (d) polarização HH e (e) composição colorida com as polarização filtradas R(VV)G(HV)B(HH).

4.3.2 DEFINIÇÃO E CARACTERIZAÇÃO DAS CLASSES TEMÁTICAS

Segundo o [IBGE \(2006\)](#), a nomenclatura das classes de cobertura da terra precisa estar adequada de modo a abranger a diversidade da área investigada, e compatível com a escala de análise, tamanho das áreas e com a fonte de dados disponíveis. A definição das classes temáticas deve ainda buscar o atendimento as necessidades daqueles que porventura utilizarão este tipo de informação.

4.3.2.1 TRABALHO DE CAMPO

O levantamento de campo teve como objetivo identificar as principais classes de uso e cobertura da terra na área de estudo e apoiar o processo de seleção das amostras de treinamento e de teste para a validação temática e geométrica. As atividades de campo ocorreram nos dias 16 e 23 de Outubro de 2010. Nesta fase da pesquisa as informações de campo são fundamentais, pois servem tanto para sugerir um número de classes quanto rejeitar o total de classes obtidas através de processos de interpretação das imagens.

A seleção das amostras em campo foi definida através da identificação de padrões de homogeneidade na paisagem, *in loco*. Tal procedimento teve por finalidade o levantamento de informações para a composição das classes temáticas a serem mapeadas. Os pontos amostrados em campo foram registrados com uso de GPS (*Global Positioning System*) e registros fotográfico.

A identificação dos diferentes tipos de uso e cobertura da terra na área de estudo foi fundamental para a definição das classes temáticas abordadas nesta pesquisa.

A área de estudo possui regiões de desmate ocorridos ao longo dos anos, sendo que uma grande parte é composta por áreas destinadas às atividades de agricultura de subsistência e pecuária. As atividades agrícolas são basicamente ligadas à produção de citros.

A região apresenta significativa formação de áreas de florestas primárias, pastagem e vegetação em diversos estágios de regeneração. Os pontos observados tanto em campo como nas imagens possibilitou a definição de 6 (seis) classes temáticas a serem mapeadas, sendo: floresta primária, floresta secundária, agricultura, pasto, solo exposto e sombreamento, sendo que a classe sombreamento foi detectada através de interpretação visual das imagens, Figura 22 e 23.

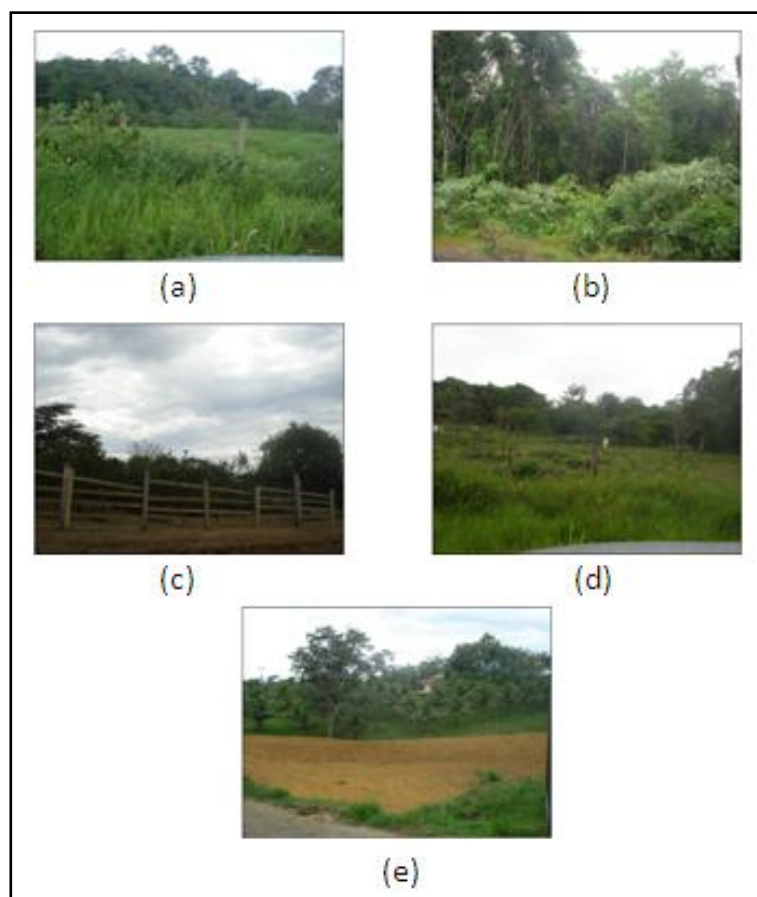


Figura 22. Feições representativas da área de estudo: (a) floresta primária, ao fundo; (b) floresta secundária; (c) Agricultura; (d) pastagem; (e) solo exposto.




Figura 23. Distribuição das classes sobre imagem em composição colorida com as polarização R(VV)G(HV)B(HH). Onde esta inclusa a classe sombreamento (f).

A classe floresta primária representa florestas que não sofreram degradação florestal ou ação de antropismo em suas características originais de estrutura. A classe floresta secundária é composta por áreas resultante de processos antrópicos, onde no passado ocorreu desmatamento da floresta primária, e também correspondem as áreas de florestas degradadas ou exploradas. A classe Agricultura está relacionada às áreas destinadas a cultivo de citros na área de estudo, enquanto que a classe pastagem representa áreas preparadas para pecuária. À classe de solo exposto, estão associados os terrenos sem cobertura vegetal, e finalmente a classe sombra que corresponde as áreas sombreadas nas imagens amplitude do SAR-R99B, ocasionadas devido a forma de coleta dos dados serem realizadas com visada lateral da aeronave. Com base nas informações adquiridas e após realização de interpretação visual na imagem foi possível estabelecer uma chave de interpretação para as classes temáticas a serem classificadas, conforme descritas na Tabela 5.

Tabela 5 - Chave da Interpretação das Classes Temáticas. Composição R(HH), R(HV) e B(VV).

Classe	Cor/Tonalidade	Textura	Forma	Padrão	Tamanho
Floresta Primária	Cinza	Granulação grossa	Regular Contínua	Vegetação Homogênea Predomina na imagem	Predominante na imagem
Floresta secundária	Marrom	Granulação grossa	Regular espaça fragmentada	Fragmentada Dispersa na imagem	Polígonos espaços e dispersos
Agricultura	Cinza escuro, Reflexo do tipo de cobertura	Granular, Evidência de cobertura	Irregular Espaça	Disposição simétrica	Polígonos dispersos na imagem
Pasto	Verde escuro	Lisa e fina	Retangular	Fragmentado contínuo	Pequenas áreas na imagem
Solo Exposto	Vermelho escuro	Lisa e fina	Sem forma definida	Fragmentado contínuo	Pequenas áreas na imagem
Sombra	Tonalidade escura	Lisa	Irregular espaça	Fragmentado dispersa	Pequenas áreas na imagem

4.3.2.2 AMOSTRAS DE TREINAMENTO E TESTE

De acordo com [Jensen \(2005\)](#), as amostras de treinamento são as referências utilizadas pelo classificador, enquanto as amostras de teste são consideradas como exemplos de referência terrestre (verdade de campo). Estas amostras são empregadas durante o processo validação e teste de acurácia dos resultados das classificações. Deve-se ser cuidadoso durante a coleta e uso dessas informações afim de não utilizar as amostras de treinamento no processo de validação das classificações.

Após o processo de definição das classes temáticas iniciou-se a coleta das amostras de treinamento e teste baseadas em áreas visitadas durante a campanha de campo. Durante este procedimento utilizou-se de critérios de interpretação visual baseados em elementos de cor, tonalidade, textura, forma e contexto das feições onde se buscou a melhor representação possível das classes temáticas. Foram coletadas amostras (polígonos) de forma que as condições de aleatoriedade e de não correlação espacial entre os pixels fossem garantidas. Ao final da coleta a variação do tamanho entre as amostras ficou entre 400 e 900 *pixels*, numero este suficiente para uma representatividade estatística significativa.

TABELA 6. Número de amostras e pixels referente as classes temáticas utilizados nas fases de treinamento e teste.

CLASSES	Treinamento		Teste	
	Pixels	ROI	Pixels	ROI
Floresta Primária	991	6	753	4
Floresta Secundaria	902	11	827	9
Pastagem	492	19	475	17
Solo Exposto	562	15	548	14
Agricultura	878	25	813	19
Sombreamento	619	6	619	6

4.3.3 AVALIAÇÃO DOS CLASSIFICADORES MAXVER-ICM E SVM.

Com a finalidade de avaliar o desempenho entre os classificadores utilizados nesta pesquisa, realizou-se classificações automáticas empregando os dois métodos nos quais utilizaram-se os mesmos conjuntos de dados. Esta etapa da metodologia visa alcançar uma resposta em detrimento do primeiro objetivo específico desta pesquisa. Portanto, nas seções a seguir serão descritos tais procedimentos.

4.3.3.1. CLASSIFICAÇÃO PELO MÉTODO MAXVER-ICM

Para a realização das classificações pelo método MAXVER-ICM foi utilizado o aplicativo Classificador Polarimétrico 0.7 (CORREIA, 1999).

Com a utilização das amostras de treinamento definidas e com os critérios de parada de 5% para a quantidade máxima de troca de pixels entre as classes (8 iterações), o classificador MAXVER-ICM foi aplicado no seguinte conjunto de polarizações das imagens em amplitude:

- Dados univariado: HH, HV e VV;
- Dados bivariados: {HH e HV}, {HV e VV}, {HH,VV};
- Dados Multipolarizado: { HH,HV e VV }.

O mesmo procedimento de classificação foi realizado com as imagens filtradas através do filtro *Gamma* 3x3. Utilizando o algoritmo MAXVER-ICM, foram no total realizadas 14 (quatorze) classificações pontuais/contextuais. O uso deste classificador possibilitou a modelagem estatística dos dados SAR univariado (Polarização HH, Polarização HV e Polarização VV), onde cada classe pode ser ajustada pela distribuição estatística que melhor represente os dados. Segundo [Vieira et al. \(1996\)](#), o classificador utilizado permite o ajuste às seguintes distribuições, Normal, Raiz quadrada da Gama, Amplitude K, Amplitude G0, Lognormal e Weibull,.

4.3.3.2 CLASSIFICAÇÃO PELO MÉTODO SUPPORT VECTOR MACHINE (SVM)

O algoritmo *Support Vector Machine* do software Envi 4.5 foi aplicado nas componentes das imagens em amplitude, distribuídos individualmente por polarizações (HH, HV e VV), em pares ($\{HH,HV\}$, $\{HV,VV\}$, $\{HH,VV\}$) e em conjunto (HH,HV e VV). Dentre as funções disponíveis no SVM optou-se por utilizar a de base radial. Tal função permite ao usuário o controle sob os parâmetros Gamma e C, aos quais foram atribuídos os valores 0,30 e 100 respectivamente.

Com as amostras das classes selecionadas (seção 4.5.2.2), foram geradas 14 (quatorze) imagens classificadas sendo: 7 (sete) para imagens em amplitude sem filtro e 7 (sete) para imagens em amplitude filtradas com *Gamma* 3x3. Em seguida o desempenho do algoritmo foi avaliado por meio de matriz de confusão, do coeficiente Kappa e dos erros de omissão e inclusão utilizando como base as amostras de testes.

4.3.4 AVALIAÇÃO DA ACURÁCIA TEMÁTICA

As classificações foram avaliadas pelos índices de concordância Kappa (CONGALTON; GREEN, 1999), gerados a partir da construção da matriz de confusão. Posteriormente, os índices Kappa foram comparados a limiares que avaliam a qualidade dessa classificação (LANDIS; KOCH, 1977).

O principal objetivo da elaboração da matriz de confusão foi estimar a concordância entre a imagem classificada e a verdade terrestre, representada pelo conjunto de amostras de teste.

Foram geradas matrizes de confusão para o conjunto de 14 classificações Maxver-ICM e 14 classificações Support Vector Machine (SVM). As matrizes foram elaboradas no software ENVI 4.5, utilizando as amostras de teste previamente definidas.

A partir das matrizes de confusão foi possível inferir a acurácia global da classificação, o valor do índice de concordância Kappa, os valores de variância do Kappa, o número de pixels classificados corretamente ou classificados erroneamente por cada classe temática, e os erros de omissão (número de pixels que pertencem a uma determinada categoria mas não são incluídos nela) e comissão (número de pixels que pertencem a outra classe mas atribuídos a classe de referência).

Os índices obtidos através das matrizes de confusão das

classificações, foram utilizados como indicador para a escolha do melhor classificador entre os métodos utilizados, assim como, o melhor conjunto de dados em amplitude classificados. Tal procedimento permitiram determinar e avaliar o potencial dos dados multipolarizados empregados nesta pesquisa..

5. RESULTADOS E DISCUSSÕES

Para melhor entendimento, nessa seção são apresentados os resultados obtidos das classificações supervisionadas realizadas através dos métodos empregados (MAXVER-ICM e SVM). Para tanto, a seqüência das informações foram divididas em tópicos conforme os objetivos proposto nesta pesquisa.

Cada tópico foi dividido em sub-tópicos de acordo com o procedimento que utilizaram as imagens com filtro e as sem filtro *Gamma 3x3*.

Em seguida são apresentados os resultados através de matriz de confusão dos dados univariados (HH, HV e VV), bivariados ({HH e HV}, {HV e VV} e {HHeVV}) e em conjunto multipolarizados (HH, HV e VV) tanto para as imagens sem filtro quanto para as filtradas com *Gamma 3x3*.

Nas tabelas subseqüentes contem os resultados gerais das classificações com os valores dos seguintes parâmetros estatísticos: Coeficiente Kappa; variância do Kappa, e a exatidão global do kappa.

5.1 AVALIAÇÃO DOS CLASSIFICADORES MAXVER-ICM E SUPPORT VECTOR MACHINE (SVM).

5.1.2 CLASSIFICAÇÃO (MAXVER-ICM)

Na classificação dos dados em amplitudes individuais (HH, HV e VV) através do software Polarimetric Classifier 0.7 (Correia, 1999) foi possível aplicar um teste de aderência qui-quadrado a fim de verificar quais as distribuições estatísticas que melhor se ajustariam às classes: floresta primária, floresta secundária, pastagem, solo exposto, agricultura e sombreamento, como parâmetro optou-se pela distribuição *normal* a um nível de significância de 5%.

5.1.2.1 MAXVER-ICM (IMAGENS SEM FILTRO)

Objetivando avaliar os resultados obtidos através do método MAXVER-ICM para os dados polarimétricos em amplitude, utilizou-se como base de comparação as tabelas de matriz de confusão obtidas através das classificações supervisionadas.

A TABELA 7 mostra os resultados para a classificação MAXVER-ICM da imagem em amplitude sem filtro onde são apresentados os valores estimados do índice Kappa, acerto global, erro global e os conceitos obtidos segundo Landis e Koch (1997).

TABELA 7. Resultado geral de exatidão das classificações MAXVER-ICM para as imagens em amplitude sem filtro.

	Maxver-ICM (sem filtro)			Conceito
	Kappa (K)	Exatidão Global (%)	Erro Global (%)	
HH	0.0637	19.55	80.4455	Ruim
HV	0.0511	19.91	80.0855	Ruim
VV	0.0440	23.42	76.5752	Ruim
HH e HV	0.0648	19.85	80.1530	Ruim
HV e VV	0.0535	18.32	81.6832	Ruim
HH e VV	0.0777	25.07	74.9325	Ruim
HH, HV e VV	0.0587	24.21	75.7876	Ruim

Com base na TABELA 7 verificou-se, de modo geral, que:

- a) Comparando os valores obtidos referente ao índice Kappa, o conjunto de dados apresentou resultados com valores muito baixos;

- b) Os resultados das classificações do conjunto dos dados em amplitude atingiram o conceito “Péssimo”, segundo os intervalos de índice Kappa estabelecidos por [Landis e Koch \(1997\)](#);
- c) O melhor resultado obtido através dos dados individuais foi para a polarização HH, obtendo-se o índice Kappa de 0.0637 e Exatidão Global de 19.55 %;
- d) Entre os conjuntos de dados utilizados aos pares e em conjunto, o melhor resultado obtido foi do par de dados {HH e VV} com índice Kappa de 0.0777 e Exatidão Global de 25.07 %;
- e) A polarização VV apresentou o menor valor obtido através da classificação, sendo, índice Kappa de 0.0440 e Exatidão Global de 23.42 %;
- f) A utilização do conjunto de dados combinados em pares ({HH e HV}, {HV e VV} e {HH e VV}) e em conjunto {HH, HV e VV}) apresentou um ganho melhor em relação aos dados em amplitude individuais (HH, HV e VV), confirmando os ganhos obtidos pelos sinergismo quando se utiliza polarizações cruzadas.

Das sete classificações realizadas pelo classificador MAXVER-ICM para a imagem amplitude sem filtro, o maior valor de *kappa* foi obtido quando se utilizou a combinação dos canais {HH e HV} (0.0648). Tal resultado apresentou nível de erro de inclusão (E.I) com média acima de 75%, considerado elevado. O baixo valor obtido do índice Kappa evidenciou que o resultado da classificação fosse considerado insatisfatório (conceito ruim) de acordo com o critério de [Landis e Koch \(1977\)](#).

Para cada conjunto de dados sejam univariados, bivariados e multipolarizados obteve-se um total de 7 classificações para a imagem em amplitude sem filtro, conforme Figura 24 à Figura 30 e TABELA 8 à TABELA 14.

5.1.2.2 MAXVER-ICM (IMAGENS FILTRADAS COM GAMMA 3X3)

Objetivando avaliar os resultados obtidos através do método MAXVER-ICM para os dados polarimétricos em amplitude filtrados com *Gamma* 3x3, utilizou-se como base de comparação as tabelas de matriz de confusão obtidas através das classificações supervisionadas.

Assim como para a análise das classificações MAXVER-ICM realizada anteriormente com as imagens sem filtro, a TABELA 15 permite concluir que a classificação das imagens filtradas, com exceção da classificação da polarização HH, apresentou resultados melhores em comparação com a classificação MAXVER-ICM das imagens não filtradas (TABELA 7) de acordo com o índice Kappa. Portanto, pode-se afirmar que neste caso a redução de ruído nas imagens utilizadas, através do uso de filtro, contribui para um melhor desempenho do classificador.

Tabela 15. Resultado geral (exatidão) das classificações MAXVER-ICM para a imagem em amplitude com filtro *Gamma* 3x3.

Maxver-ICM (com filtro Gamma 3x3)				
	Kappa (K)	ExatidãoGlobal (%)	Erro Global (%)	Conceito
HH	0.0595	19.4644	80.5356	Ruim
HV	0.0704	19.8020	80.1980	Ruim
VV	0.0400	22.7948	77.2052	Ruim
HH e HV	0.0693	20.7471	79.2529	Ruim
HV e VV	0.0624	19.6670	80.3330	Ruim
HH e VV	0.0849	25.0675	74.9325	Ruim
HH, HV e VV	0.0720	21.3546	78.6454	Ruim

Nas classificações realizadas com os dados univariados (HH, HV e VV), o pior resultado foi obtido pelo canal VV (kappa de 0.0400) o que confirmou o resultado obtido por essa mesma polarização sem o uso de filtro. Diferentemente das imagens sem filtro, o melhor resultado entre dados univariados ficou com a polarização HV (kappa de 0.0704).

Com relação as classificações bivariadas, o melhor resultado foi obtido quando se utilizou a combinação {HH e VV} (kappa de 0.0849 e exatidão global de 25.07 %). Os demais pares, {HH e HV} e {HV e VV}, apresentaram resultados bem próximos com kappa de 0.0693 e 0.0624 respectivamente.

Na classificação dos dados multipolarizados, {VV, HV e HH}, o resultado

obtido (kappa de 0.0720) foi inferior em comparação aos dados da combinação {HH e VV}. Os dados multipolarizados apresentaram elevados valores de erro de inclusão (E.I), com média em torno de 78% entre as classes mapeadas, o que impactou no resultado referente a exatidão global que foi de 21.35%.

De forma geral, percebeu-se uma melhora pouco significativa nos valores percentuais, referente ao índice kappa e exatidão global, dos resultados nas imagens onde a técnica de filtragem foi empregada. No entanto os resultados obtidos com imagens filtradas apresentaram valores relativamente baixos com relação ao índice kappa, os quais de acordo com o critério de [Landis e Koch \(1977\)](#) foram classificados com conceito “ruim” em todo o conjunto de dados utilizados.

Para cada conjunto de dados sejam univariados, bivariados e multipolarizados obteve-se um total de 7 classificações para a imagem em amplitude com filtro *Gamma* 3x3, conforme ilustra as Figura 31 à Figura 37 e TABELA 16 à TABELA 22.

5.1.3 CLASSIFICAÇÃO *SUPPORT VECTOR MACHINE* (SVM)

O algoritmo *Support Vector Machine* do software Envi 4.5 foi aplicado nas componentes das imagens em amplitude, distribuídos individualmente por polarizações (HH, HV e VV), em pares ($\{HH \text{ e } HV\}$, $\{HV \text{ e } VV\}$, $\{HH \text{ e } VV\}$) e em conjunto (HH, HV e VV). Dentre as funções disponíveis no SVM optou-se por utilizar a de base radial. Tal função permite ao usuário o controle sob os parâmetros Gamma e C, aos quais foram atribuídos os valores 0,30 e 100 respectivamente.

Objetivando avaliar os resultados através do método SVM (*Support Vector Machine*, para os dados polarimétricos em amplitude, utilizou-se como base de comparação os resultados obtidos através de classificação supervisionada.

Com as amostras das classes selecionadas (seção 4.2.2), foram geradas 14 (quatorze) imagens classificadas sendo: 7 (sete) para imagens em amplitude sem filtro e 7 (sete) para imagens em amplitude com filtro *Gamma* 3x3. Em seguida o desempenho do algoritmo foi avaliado por meio de matriz de confusão, com base nos valores do coeficiente Kappa, variância do Kappa, e a exatidão global do kappa.

5.1.3.1 SVM (IMAGENS SEM FILTRO)

Para as componentes de dados utilizados sejam em forma individual, aos pares e em conjunto obteve-se um total de 7 classificações para a imagem em amplitude, e foram geradas suas respectivas matrizes de confusão. Em seguida são apresentados os resultados (TABELA 23) dos valores estimados referente aos índices de Kappa, Exatidão Global (%), Erro Global (%) e os conceitos alcançados, conforme a classificação de [Landis e Koch \(1997\)](#).

TABELA 23. Resultado geral de exatidão das classificações SVM para a imagem em amplitude sem filtro.

SVM (sem filtro)				
	Kappa	Acerto Global (%)	Erro Global (%)	Conceito
HH	0.4951	58.59	41.41	Bom
HV	0.5149	59.99	40.01	Bom
VV	0.4884	57.92	42.08	Bom
HH e HV	0.5653	64.15	35.85	Bom
HV e VV	0.4843	56.67	43.33	Bom
HH e VV	0.4833	57.62	42.38	Bom
HH, HV e VV	0.6940	74.82	25.18	Muito Bom

Com base na TABELA 23 verifica-se que os resultados obtidos referente ao índice Kappa das classificações nas imagens sem filtros apresentaram valores satisfatórios em todo o conjunto de dados avaliados, os quais apresentaram Acerto Global acima de 50% em todas as classificações realizadas. Tal fato indica que o classificador Support Vector Machine (SVM) obteve índice de classificação “muito bom” conforme o conceito alcançado.

De acordo com a análise dos dados e a comparação entre as matrizes de confusão das classificações, imagens em amplitude, das componentes individuais (HH, HV e VV) pode-se inferir que a polarização HV apresentou o melhor resultado, com valor do índice Kappa em torno de 0.51 e Exatidão Global com 59.99%. Entretanto, ao averiguar os valores referente ao erro de inclusão (E.I.) e o erro de omissão (E.O.) percebe-se que as classes temáticas Floresta Secundária e Agricultura apresentaram valores elevados de erro de inclusão, para ambas as classes, acima de 60% e erro de omissão em 95.43% (Floresta Secundária) e 41.80% (Agricultura). Valores

estes, indicam a dificuldade em classificar as referidas classes através do conjunto de amostras e classificador utilizado.

Análise comparativa entre os resultados referente as polarizações HH e VV, o classificador SVM obteve melhor desempenho com a polarização HH fazendo com que os erros de inclusão (E.I.) fossem menores. Assim o menor índice obtido entre as componentes individuais foi para a polarização VV que alcançou índice Kappa de 0.4884 e Exatidão Global em torno de 57.92%.

Para as classificações das componentes em pares ({HH e HV}, {HV e VV} e {HH e VV}) o melhor resultado alcançado foi da combinação {HH+HV} (Kappa de 0.5653 e Exatidão Global de 64.15%). O par {HH e VV} apresentou valores levemente menores que a combinação {HV e VV}. Conforme as tabelas de matriz de confusão ambos apresentaram valor Kappa de 0.4833 e 0.4843 respectivamente.

Das classificações realizadas nas imagens em amplitude sem filtro com o classificador SVM o maior valor de Kappa obtido foi quando se utilizou a combinação das componentes {VV, HV e HH}. A Classificação para as três polarizações usadas em conjunto apresentou valor Kappa de 0,6940 e Exatidão Global de 74,82%, e também apresentou os menores valores referente a erro de inclusão entre as demais classificadas. Assim justificando a melhor acurácia entre as classes temáticas mapeadas.

A seguir são ilustrados e apresentados os resultados das classificações (Figura 38 à Figura 44) com suas respectivas matrizes de confusão. (TABELA 24 à TABELA 30).

5.1.3.2 SUPPORT VECTOR MACHINE (IMAGENS FILTRADAS - GAMMA 3X3)

Para as componentes de dados utilizados sejam em forma individual, aos pares e em conjunto obteve-se um total de 7 classificações para a imagem em amplitude filtrada com filtro *Gamma* 3x3, e foram geradas suas respectivas matrizes de confusão. Em seguida são apresentados os resultados (TABELA 31) dos valores estimados referente aos índices de Kappa, Exatidão Global (%), Erro Global (%) e os conceitos alcançados, conforme a classificação de [Landis e Koch \(1997\)](#).

TABELA 31. Resultado geral de exatidão das classificações SVM para a imagem em amplitude com filtro *Gamma* 3x3.

SVM (Filtro Gamma 3x3)				
	Kappa	Acerto Global (%)	Erro Global (%)	Conceito
HH	0.5696	64.76	35.24	Bom
HV	0.6033	67.34	32.66	Muito Bom
VV	0.6070	67.61	32.39	Bom
HH e HV	0.5979	67.01	32.99	Muito Bom
HV e VV	0.5820	65.63	34.37	Bom
HH e VV	0.5556	63.50	36.50	Bom
HH, HV e VV	0.7736	81.37	18.63	Muito Bom

Com base na TABELA 31 verificou-se que os resultados obtidos referente ao índice Kappa das imagens filtradas apresentaram valores satisfatórios em todo o conjunto de dados avaliado, sendo que os conjunto de dados que fizeram uso da polarização cruzada alcançaram um melhor rendimento em seus resultados.

Ao analisar as matrizes de confusão obtidas através das componentes individuais (HH, HV e VV) é possível observar que a polarização HH apresentou o menor valor para o índice Kappa (0.5696), a partir dos valores de erro de inclusão (E.I) e erro de omissão (E.O) que foram de 57,39% e 78.36% respectivamente pode-se inferir que tal polarização apresentou limitação para a detecção da classe temática Agricultura, com base nas amostras utilizadas, por terem apresentado os maiores valores entre as classes classificadas.

A classificação SVM da polarização VV foi a que apresentou os melhores índices entres as componentes individuais, onde os maiores valores dos erros

de inclusão (E.I) e erros de omissão (E.O) ficaram um pouco acima de 50%, correspondentes a classe temática Floresta Secundária. Sendo que foram alcançados os valores de 0.6070 para o índice Kappa e 67.61% para o valor referente à Exatidão Global.

Entre as classificações das componentes em pares ({HH e HV}, {HV e VV} e {HH e VV}), os números alcançados indicam que o melhor resultado foi da combinação {HH e HV} apresentando o valor de Kappa de 0.5979 e Exatidão Global de 67.01%. Entretanto para classe temática Agricultura o erro de omissão (E.O) atingiu a cota máxima de 100%, valor este que indica a não possibilidade de detecção desta classe temática através das amostras utilizadas pelo classificador. O par das polarizações {HH e VV} apresentaram o menor valor de índice Kappa e Exatidão Global que foram de 0.5556 e 63.60% respectivamente.

Ao utilizar o classificador SVM com o conjunto das três componentes (VV, HV e HH), foi alcançado o maior valor de Kappa (0.7738) e de Exatidão Global (81.37%). Comparando este resultado com das outras componentes (individual e em par) constata-se que tanto o erro de inclusão (E.I.) quanto o erro de omissão foram os menores alcançados entre as classificações, os quais alcançaram valores abaixo de 40%, sendo assim considerada como uma acuraria muito boa na estratificação de conceitos de [Landis e Koch \(1997\)](#).

A seguir são ilustrados e apresentados os resultados das classificações (Figura 45 à Figura 51) com suas respectivas matrizes de confusão. (Tabela 32 à Tabela 38).




Figura 49. Classificação SVM, utilizando a polarização HV+VV com filtro *Gamma* 3x3.

TABELA 36. Matriz de confusão da classificação SVM, canais HV+VV com filtro *Gamma* 3x3.

SVM HV+VV (filtro Gamma 3x3)									
Classes	Floresta Primaria	Floresta Secundaria	Pastagem	Solo Exposto	Agricultura	Sombra	Total	E.I (%)	A.U (%)
Floresta Primaria	727	168	0	0	31	0	926	21.49	78.51
Floresta Secundaria	209	444	0	0	240	0	893	50.28	49.72
Pastagem	0	0	150	145	0	0	295	49.15	50.85
Solo Exposto	1	5	336	394	24	0	760	48.16	51.84
Agricultura	54	285	6	23	583	0	951	38.70	61.30
Sombra	0	0	0	0	0	619	619	0.00	100.00
Total	991	902	492	562	878	619	4444		
E.O (%)	26.64	50.78	69.51	29.89	33.60	0.00			
A.P. (%)	73.36	49.22	30.49	70.11	66.40	100.00			
kappa	0.5820								
Var(kappa)	0.0000748								
Exatidão Global (%)	65.63								

5.2 ANÁLISE DA INFLUÊNCIA DO USO DE FILTRO GAMMA 3X3

Com intuito de analisar a influência da técnica de filtragem do speckle nos resultados das classificações supervisionadas realizadas nesta pesquisa, utilizou-se como parâmetro a comparação entre os valores do índice Kappa, obtidos com imagens filtradas e sem filtros.

As Figura 52 e 53 apresentam o comportamento do índice Kappa em função dos graus de exatidão para conjunto de dados filtrados com *Gamma* com janela 3x3 pixels, utilizando os classificadores MAXVER-ICM e Support Vector Machine, respectivamente.




Figura 52. Distribuição dos índices Kappa das classificações SVM das imagens em amplitude sem filtro e com filtro (*Gamma* 3x3).




Figura 53. Distribuição dos índices Kappa das classificações SVM das imagens em amplitude sem filtro e com filtro (*Gamma* 3x3).

Analisando a figura 52 referente as informações geradas a partir do classificador MAXVER-ICM observou-se que, no geral, o uso da técnica de filtragem possibilitou um desempenho positivo na ordem de 0,6 % em relação ao uso de imagens sem filtros. Com relação ao conjunto dos dados univariados a polarização HV respondeu com desempenho positivo enquanto as demais (HH e VV) o desempenho alcançado foi o oposto. Também foi possível notar que o conjunto de dados que utilizaram a polarização cruzada HV obtiveram resultados positivos que colaboraram para o desempenho do classificador utilizado.

Sobre a análise de desempenho do uso de filtragem com o classificador *Support Vector Machine* (SVM) pode-se afirmar que em todo o conjunto de dados utilizados o resultado foi significativo, o qual permitiu um acréscimo de desempenho em média na ordem de 8% . Ao analisar o conjunto de dados individualmente tanto os dados univariados, em pares e os multipolarizados observa-se que os mesmos apresentaram desempenho positivo distintos, com uma variação entre 7% a 12% .

No geral, a aplicação do filtro provocou um incremento positivo no resultados em relação ao obtido com a imagem sem filtro. Tal fato comprova que o uso adequado de filtros para atenuação de ruídos em imagens de radar pode colaborar para um melhor desempenho no processo de classificação automática.

5.3. INDICAÇÃO DO MELHOR CONJUNTO (CLASSIFICADOR, POLARIZAÇÃO, IMAGEM BRUTA OU IMAGEM FILTRADA) PARA DISCRIMINAÇÃO DAS CLASSES TEMÁTICAS.

Ao finalizar todas as etapas envolvidas no procedimento metodológico proposto nesta pesquisa, e com a mensuração dos resultados obtidos através do uso de classificadores automáticos distintos juntamente com o conjunto de dados de radar multipolarizados empregados, foi possível determinar o melhor conjunto de ferramentas do ponto de vista de qual classificador, conjunto de dados e imagem de radar seria, de certa forma, o ideal para mapeamento de uso e cobertura da terra.

Portanto, de acordo com o experimento realizado o melhor resultado alcançado foi possível quando se fez uso do conjunto das três componentes (VV+HV+HH) das imagens em amplitude filtradas (Gamma 3x3) através do classificador *Support Vector Machine* (SVM).

A Figura 54 ilustra o mapa temático referente ao melhor resultado obtido entre as avaliações dos classificadores utilizados e o conjunto de dados empregados.

Em uma área total de aproximadamente 11 km², as áreas quantificadas referente as classes mapeadas estão distribuídas da seguinte forma: 1.45 km² (12.9 %) de floresta primária; 1.33 km² (11.9 %) de floresta secundária; 2 km² (18.3 %) de área de pasto; 2.5 km² (23%) de solo exposto; 2.8 km² (25 %) para a classe agricultura e 0.9 km² (8.3 %) para a classe sombra. A acurácia global desse mapeamento temático foi de aproximadamente 81.37 %, com índice Kappa no valor de 0.7736.

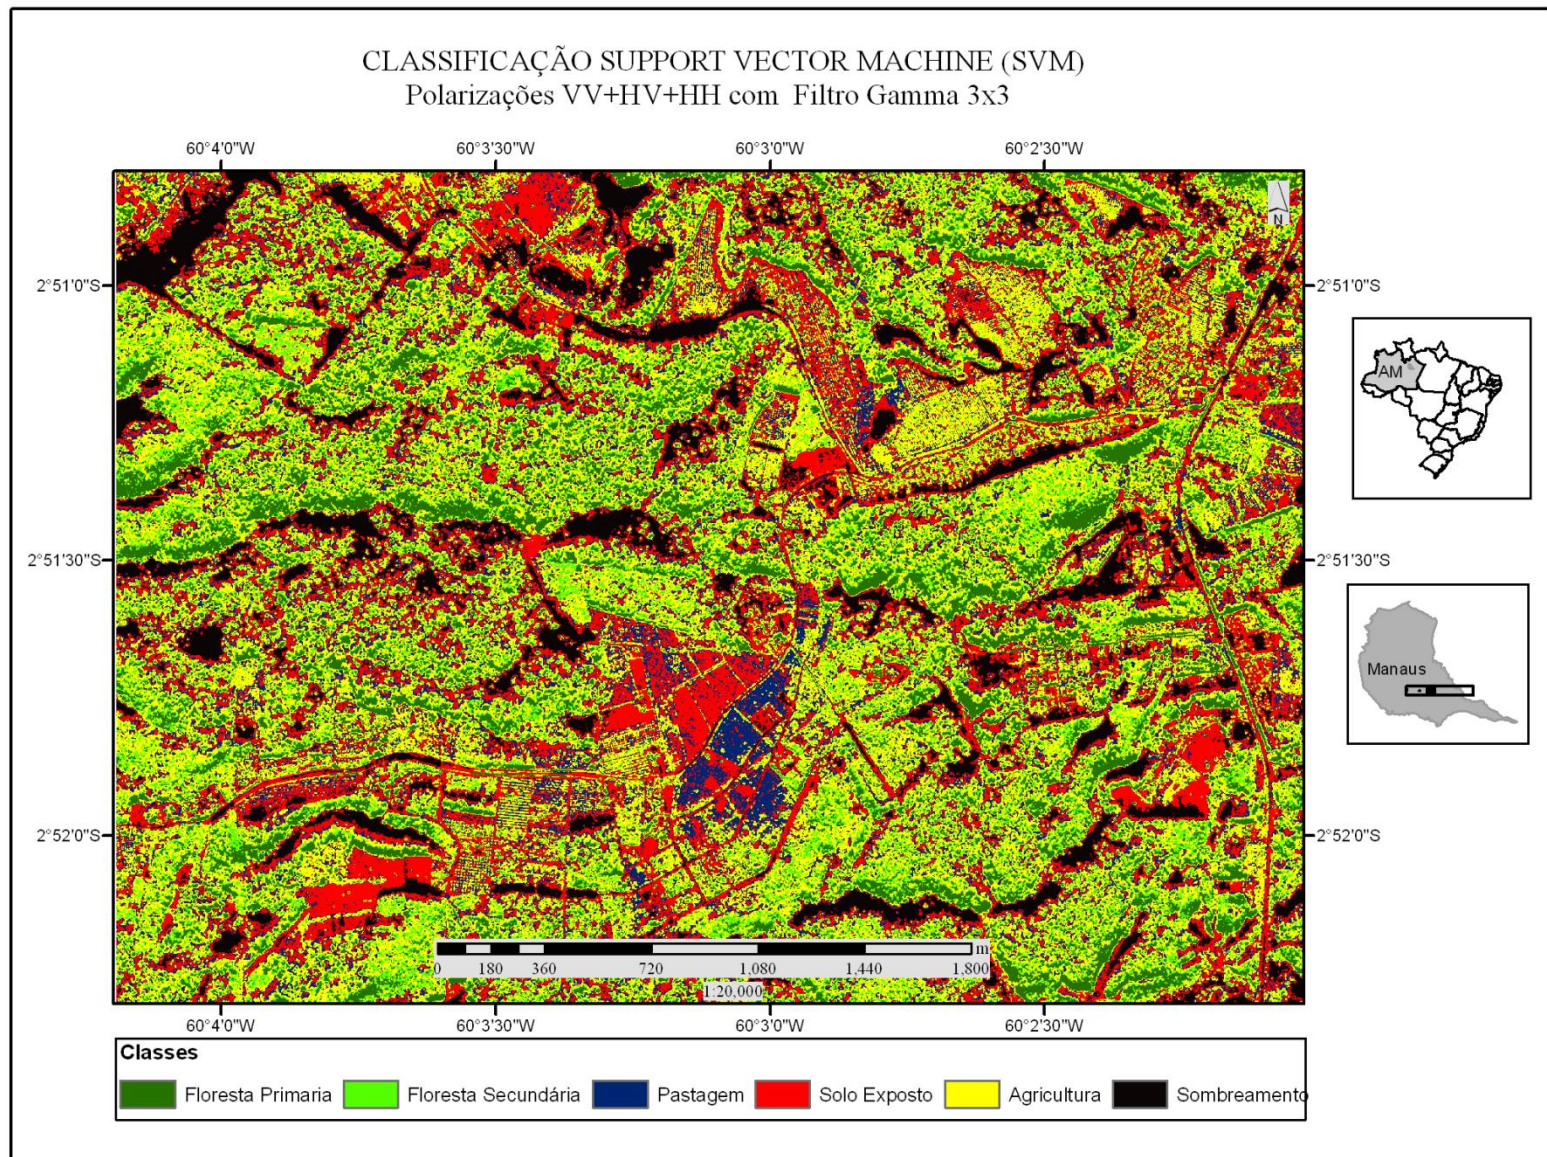


Figura 54. Mapa temático resultante da classificação SVM com os dados multipolarizados.

6. DISCUSSÕES

As imagens polarimétricas do sensor SAR-R99B foram consideradas de forma geral adequadas para a identificação das classes de uso e cobertura da terra definida neste trabalho, no qual foi considerado somente os dados no formato amplitude.

Avaliando os métodos de classificação para identificação das classes temáticas definidas neste trabalho, é possível afirmar que o algoritmo *Support Vector Machine* (SVM) apresentou melhor desempenho quando comparado com o algoritmo MAXVER-ICM. O melhor resultado alcançado pelo algoritmo SVM foi com conjunto de 3 três polarizações (VV, HV e VV) (imagens filtradas) enquanto que o algoritmo MAXVER-ICM apresentou como melhor resultado o par de polarizações (HH e VV) (imagens filtradas).

O uso do filtro Gamma (3x3) contribui significativamente para o desempenho nos processos de classificações empregados. A análise dos dados revelou que os classificadores têm seu comportamento alterado de acordo com o pré-processamento das imagens.

Os valores dos erros de omissão (E.O.) observados nas classes diferentes da classe Floresta Primária na polarização HH (SVM com imagem filtrada) pode ser justificado pela diminuição do retorno do sinal em dados adquiridos através de banda L. Em [Rignot et al., \(1997\)](#), [Almeida Filho et al., \(2005\)](#) e [Dutra et al., \(2007\)](#) estão relatados as dificuldades encontradas durante o processo de detecção de estágios iniciais de desflorestamento com imagens multipolarizadas.

A utilização da polarização cruzada HV em par e em conjunto com as demais polarizações, em ambos os algoritmos utilizado, propiciou um melhor rendimento nos resultados.

Os resultados revelados (SVM com imagens filtradas) indicaram que o par de polarizações (HH e HV), considerando o dado em amplitude, é suficiente para discriminação das classes temáticas em questão. Tal fato difere do resultado obtido por [Santos et. al. \(2008\)](#) que aponta o par de polarizações (HV e VV) como o melhor para discriminar desflorestamento.

Através do uso em conjunto de 3 (três) polarizações (VV, HV e HH) das imagens filtradas e o algoritmo SVM obteve-se o maior valor referente à avaliação temática, demonstrando assim a importância de dados de radar multipolarizados para a

discriminação de diferentes classes de uso e cobertura da terra, o resultado obtido com o uso de três polarizações está de acordo com o apresentado por [Guerra *et al.* \(2010\)](#).

7. CONCLUSÕES E RECOMENDAÇÕES

Este trabalho teve como objetivo principal investigar o potencial dos dados do sensor SAR R99-B (Banda L) para discriminar classes de uso e cobertura da terra na Amazônia, região de Manaus-AM,

A metodologia aplicada através de tratamento das imagens e coleta de dados em campo mostrou-se suficientemente adequada para subsidiar as análises advinda dos dados de radar.

Os dados de radar em Banda L possuem um bom potencial para discriminação das classes temáticas definidas nesta pesquisa. Através de tal fato pôde-se confirmar a hipótese deste trabalho.

A sensibilidade dos dados SAR-R99B em regiões de florestas mostra o quanto é complexa tal interação, e conseqüentemente a interpretação de resultados. Devido às estruturas de cobertura, à plataforma de aquisição utilizada e às condições climáticas. No entanto, superada as dificuldades, foi possível demonstrar a utilização de dados polarimétricos como ferramenta no âmbito de mapeamento de classes temáticas.

O classificador MAXVER-ICM não apresentou um desempenho satisfatório na classificação dos dados SAR R99-B.

O classificador Support Vector Machine (SVM) apresentou uma performance relativamente boa de acordo com o critério de avaliação temática aplicado.

Para ambos os classificadores o uso de imagens filtradas permitiu atingir resultados melhores que os das imagens sem filtro.

A classificação com maior valor Kappa foi obtida quando se utilizou o classificador SVM com conjunto de 3 (três) polarizações, VV+HV+VV, para imagem em amplitude filtrada. Que apresentou o valor Kappa de 0.7736 alcançando conceito “muito bom”.

Por fim, pode-se inferir que o uso de imagens de radar no mapeamento de classes temáticas em regiões tropicais pode ser considerado como uma proposta viável.

Sugere-se para trabalhos futuros o uso de conjunto de imagens em distintos períodos sazonais, o que permitirá identificar novas configurações no que se refere aos atributos espaciais ocupados pelas classes de uso e cobertura da terra no qual viabilizará uma melhor discussão sobre o assunto. Recomenda-se ainda o uso de dados complexos com o intuito de verificar a influência da informação de fase nos

mapeamentos temáticos.

Os procedimentos metodológicos adotados mostraram-se adequados para serem utilizados com os dados polarimétricos, não havendo restrição para serem aplicados em outras áreas de estudo. Entretanto, é necessária a adoção de critérios cuidadosos para seleção e aquisição de amostras representativas de cada classe de interesse. Essa replicabilidade torna o procedimento adotado passível de ser utilizado em pesquisas semelhantes.

8. REFERÊNCIAS

ABOUD NETA, S. R.; DUTRA, L. V.; SCOFIELD, G. B.; NEGRI, R. G.; FREITAS, C. C.; SILVA, D. L. A. **Comparação entre classificação contextual e classificação por regiões para mapeamento de uso e cobertura da terra na região da Floresta Nacional de Tapajós - PA (FLONA): utilizando imagens polarimétricas em banda L.** In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7749-7756. DVD, On-line. ISBN 978-85-17- 00044-7. (INPE-15793-PRE/10405).

ALMEIDA FILHO, R.; ROSENQVIST, A.; SHIMABUKURO, Y. E.; DOS SANTOS, J. R. 2005. **Evaluation and perspectives of using multitemporal L-band SAR data to monitor deforestation in the Brazilian Amazonia.** IEEE Geoscience and Remote Sensing Letters, 2(4): 409-412.

ALMEIDA FILHO, R.; ROSENQVIST, A.; SHIMABUKURO, Y. E.; SILVA GOMEZ, R. **Detecting deforestation with multitemporal L-band SAR imagery: a case study in western Brazilian Amazon.** International Journal of Remote Sensing, v. 28, n. 6, 2007.

ALMEIDA, F. C. **Simulação de resposta de estruturas simplificadas de vegetação ao radar de abertura sintética interferométrico.** 2008. 102 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2008.

ANDRADE, N. S. O. **Qualidade geométrica de imagens JERS-1 (SAR) e Radarsat (modos S2 e S3) em ambiente de floresta tropical (Rondônia).** 1999, 204p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1999.

ASNER, G. P. **Cloud cover in Landsat observations of the Brazilian Amazon.** International Journal of Remote Sensing, v. 22, n. 18, p. 3855-3862, 2001.

BORGES, R. O., et al. (2007). **Métodos e Técnicas de Registro de Imagens SAR/SIPAM a partir de Dados Orbitais Ópticos e Sensores SAR/SIPAM.** In: XIII Simp. Bras. de Sens. Rem., Florianópolis, INPE. p.4819-4826, 2007.

BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. **Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais.** In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 813-822.

BUFALO, A. C. **Avaliação da aplicação de mosaicos de dados de radar da missão demapeamento de florestas pluviais ao monitoramento do desmatamento na Amazônia Brasileira.** 2005, 169p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2005.

CAMARA, G., SOUZA, R. C. M., FREITAS, U. M., GARRIDO, J. **SPRING: Integrating remote sensing and GIS by object oriented data modelling,** Computers & Graphics, 20: (3) 395-403, 1996.

CAMPBELL, J. B. **Introduction to remote sensing**. 4. ed. New York: The Guilford Press, 2007. 626p.

CANADA CENTRE FOR REMOTE SENSING (CCRS) Tutorial: **Fundamentals of remote sensing**. 2007. 258 p. [on line]. Disponível em: <http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/pdf/fundamentals_e.pdf >. Acesso em 10 Dez. 2009.

CONGALTON, R.G.; GREEN, K. G. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Boca Raton, FL, 1999. 137 p.

CONGAR. **Produtos disponibilizados a partir dos sensores das aeronaves R99-B (SAR, MSS e OIS) e C98-B (HSS)**. Comando da Aeronáutica, 25p., 2004.

CORREIA, A. H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. Dissertação de Mestrado, Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 271 p., 1999.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: Unicamp, p. 170. 1992.

DALLEMAND, J.F.; LICHTENEGGER, J.; RANEY, R.K.; SCHUMANN, R. **Radar imagery: theory and interpretation: lecture notes**. Rome: FAO/ESA, 1993. (RSC Series 67).

DOBSON, M. C. **Forest information from Synthetic Aperture Radar**. Journal of Forestry. n.98, p.41-43, 2000.

DOBSON, M.C.; ULABY, F.T.; LETOAN, T.; BEAUDOIN, A.; KASISCHKE, E.S.; CHRISTENSEN, N. **Dependence of radar backscatter on coniferous forest biomass**. IEEE Transactions on Geoscience and Remote Sensing v. 30: p.412–415. 1992.

DUTRA, L. V.; SCOFIELD, G.; ABOUD, S. R. N.; NEGRI, R. G.; FREITAS, C. C.; MURA, J. C.; SANT'ANNA, S.; GAMA, F. F. 2007. **ALOS/ PALSAR polarimetric data for land use/land cover classification in Amazon**. In: Te First Joint PI Symposium of ALOS Data Nodes for ALOS Science Program, Kyoto, Proceedings. JAXA: Kyoto, 2007.

DUTRA, L. V.; SCOFIELD, G. B.; ABOUD, S. R. N.; NEGRI, R. G.; FREITAS, C. C.; ANDRADE, D. **Land Cover Classification in Amazon using Alos Palsar Full Polarimetric Data**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7259-7264. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15865-PRE/10475).

EASTMAN, J.R. 1999. Idrisi 32: **Guide do GIS and Image Processing**. Clark: Worcester. Vol.1: 193p. e Vol.2:170p.

ESCADA, M. I. S. **Evolução de padrões da terra na região centro-norte de Rondônia**. 2003. 264 p. (INPE-10209-TDI/899). Tese (Doutorado em Sensoriamento

Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2003.

FOODY, G. M. **Status of land cover classification accuracy assessment**. Remote Sensing of Environment, v. 80, n. 1, p. 185-201, 2002.

FREITAS, C. C.; SOLER, L. S.; SANT'ANNA, S. J.S.; DUTRA, L. V.; SANTOS, J. R.; MURA, J. C.; CORREIA, A. H. **Land use and land cover mapping in the Brazilian Amazon using airborne P-band SAR data**. IEEE Transactions on Geoscience and Remote Sensing, v. 46, n. 10, 2008.

FRERY, A. C.; CORREIA, A. H.; FREITAS, C. C. **Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information**. IEEE Transactions on Geoscience and Remote Sensing, vol. 45, n. 10, p. 3098 - 3109, 2007.

GABOARDI, C. **Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós**. 2002. 139 p. (INPE-9612-TDI/842). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2002.

GIDUDU A.; HULLEY G.; MARWALA T. **Image Classification Using SVMs: One-against-One Vs One-against-All**. In: Asian Conference on Remote Sensing (ACSR), 28, 2007, Kuala Lumpur. Proceedings... Singapore: ACSR, 2007.
Disponível em: < <http://arxiv.org/abs/0711.2914v1>>. Acesso em: 05 Dez. 2010.

GOODENOUGH, D. G.; CHEN, H.; DYK, A. **Evaluation of Convair-580 and simulated Radarsat-2 polarimetric SAR for forest change detection**. In: International Geoscience and Remote Sensing Symposium, 2006, Barcelona. Proceedings...Barcelona: IEEE, 2006.

GRAY, A. L.; VACHON, P. W.; LIVINGSTONE, C. E.; LUKOWSKI, T. L. (1990). **Synthetic Aperture Radar calibration using reference reflectors**. IEEE Transactions on Geoscience and Remote Sensing, v. 28, n. 3, p.374 – 383.

GREEN, K.; KEMPKA, D.; LACKEY, L. **Using remote sensing to detect and monitor landcover and land- use change**. Photogrammetric Engineering and Remote Sensing, v.60, n.3, p.331-337, Mar. 1994.

GUERRA, J. B.; FREITAS, C. D. C.; MURA, J. C. **Evaluation of the potential of L band POL SAR data to discriminate deforestation increment areas in Amazon rain forest**. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'08), 2008, Boston, USA. Proceedings... 2008.

HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

HENDERSON & A.J. LEWIS, 1998. **PRINCIPLES & APPLICATIONS OF IMAGING RADAR, MANUAL OF REMOTE SENSING, V.2**, NEW YORK, AM. SOC. PHOT. AND REM. SENS., 1998. P.733-768.

HOEKMAN, D.H.; QUIÑONES, M.J. **Biophysical forest type characterization in the Colombian Amazon by airborne polarimetric SAR.** IEEE Transactions on Geoscience and Remote Sensing, v. 40, n.6, p. 1288-1300, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual Técnico de uso da terra.** Manual Técnico em Geociências número 7. 2. ed. Divisão de Geociências. Rio de Janeiro, 2006. 91 p.

JENSEN, J. R. **Remote Sensing of the Environment an Earth Resource Perspective.** Upper Saddle River, New Jersey: Prentice Hall, 2000. 544 p.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective.** 3. ed. Upper Saddle River, NJ: Prentice-Hall, 2005. 526 p.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective.** 2. ed. Upper Saddle River, NJ: Prentice-Hall, 2007. 592 p.

KASISCHKE, E.S.; MELACK, J.M.; DOBSON, C.M. **The use of imaging radars for ecological applications-A review.** Remote Sensing of Environment, v. 59, n.2, p. 141-156, 1997.

KUPLICH, T. M. **Estudos florestais com imagens de radar.** Espaço & Geografia, v. 6, n.1, p. 65-90, 2003. ISSN: 1516-9375

KUPLICH, T.M.; CURRAN, P.J.; ATKINSON, P.M. **Relating SAR image texture and backscatter to tropical forest biomass.** In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2003). Toulouse. **Proceedings...** Toulouse: IEEE Piscataway. IEEE. V.IV. p.2872-2874, 2003.

LANDIS, J. R.; KOCH, G. G. **The measurements of observer agreement for categorical data.** Biometrics, v. 33, p. 159-174, 1977.

LAMBIN, E. F.; GEIST, H. J.; LEPERS, E. **Dynamics of land-use and land-cover change in tropical regions.** Annual Review Environment Resources, v. 28, p. 205-241, 2003.

LECKIE, D. G., RANSON, K. J. **Forestry applications using imaging radar.** In: **Principles and Applications of Imaging Radar.** (F. M. Henderson, and A. J. Lewis, Eds.). New York: John Wiley, p. 435-509, 1998.

LEE, J. S.; GRUNES, M. R. **Feature classification using multi-look polarimetric SAR imagery.** In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'92) Houston, May 26-29, 1992. International space year: space remote sensing. Piscataway: IEEE, 1992. v.1, p.77-79.

LEE, J. S.; GRUNES, M. R.; POTTIER, E. Quantitative comparison of classification capability: fully polarimetric versus dual and single-polarization SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n.11, p. 2343-2351, 2001.

LE TOAN, T.; BEAUDOIN, A.; GUYON, D. **Relating forest biomass to SAR data.**

IEEE Transactions on Geoscience and Remote Sensing, v. 30, n.2, p. 403-411, 1992.

LEWIS, A. J., HENDERSON, P.M., HOLCOMB, D.W. 1998. **Radar fundamentals: the geoscience perspective**. In: LEWIS, A.J.; HENDERSON, F.M. Manual of remote sensing: principles and applications of imaging radar. 3 ed. New York: American Society for Photogrammetry and Remote Sensing, 1998. 866p.

LILLESAND, T. M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. New York: J. Wiley. 750p., 1994.

LOPES, A.; TOUZI, R.; NEZRY, E. Adaptive speckle filters and scene heterogeneity. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 6, p. 992-1000, 1990.

MATHER, P. M. **Computer processing of remotely sensed images: an introduction**. 2nd ed. Chichester: John Wiley & Sons, 1999. 292p. ISBN (0-471-98550-3).

MILNE, A. K.; DONG, Y. **Vegetation mapping using JERS-1 SAR mosaic for northern Australia**. International Journal of Remote Sensing, v. 23, n.7, p. 1475 - 1486, 2002.

MORAIS, M. C. **Discriminação de lateritas mineralizadas em ferro no depósito N1 (Carajás-PA) por radar imageador : uma avaliação através de classificação textural**. 193 p. Dissertação de Mestrado em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998.

MURA, J. C.; CORREIA, A. H.; HONDA, P. 2007. **Calibração preliminar dos dados SAR polarimétricos em banda L do sensor R99B do CENSIPAM**. In: Simp. Bras. de Sens. Rem., Florianópolis, INPE. 13

PARADELLA, W. R.; SANTOS, A. R.; VENEZIANI, P.; MORAIS, M. C. **Synthetic aperture radar for geological applications in the moist tropics: experiences from the brasilian Amazon region**. Revista Brasileira de Geociências, v. 30, n. 3, p. 538-542, 2000.

PARADELLA, W.R.; OLIVEIRA, C.G.; LUIZ, S.; CECARELLI, I.C.F.; COTTINI, C.P.; OKIDA, R. **Operational use of RADARSAT-1 fine stereoscopy integrated with Landsat-5 thematic mapper data for cartographic application in the Brazilian Amazon**. Canadian Journal of Remote Sensing, Vol. 31, N° 2, pp. 139–148. 2005.

PARADELLA, W. R. ; SANTOS, A. R. ; VENEZIANI, P. ; CUNHA, E. S. P. **Radares imageadores nas geociências: estado da arte e perspectivas**. Revista Brasileira de Cartografia n. 57/01, 2005, p. 56-62.

PODEST, E.; SAATCHI, S. **Application of multiscale texture in classifying JERS-1 radar data over tropical vegetation**. International Journal of Remote Sensing, v. 23, n.7, p. 1487 - 1506, 2002.

POTTIER, E.; LEE, J. S. **Application of H/A/alpha polarimetric decomposition theorem for unsupervised classification of fully polarimetric SAR data based on**

the Wishart distribution. In: CEOS Workshop, 1999. Proceedings... Publications Division: Noordwijk, The Netherlands, 1999.

RAYTHEON COMPANY, 1998. **Airborne Synthetic Aperture Radar Subsystem Specification.** Lexington, Raytheon Company. G628676. Revisão M.

RIGNOT, E.; SALAS, W. A.; SKOLE, D. L. **Mapping deforestation and secondary growth in Rondônia, Brazil, using imaging radar and thematic mapper data.** Remote Sensing of Environment, v. 59, n.2, p. 167-179, 1997.

ROSENQVIST, A.; MILNE, A.; LUCAS, R.; IMHOFF, M.; DOBSON, C. **A review of remote sensing technology in support of the Kyoto Protocol.** Environmental Science & Policy, v. 6, n.5, p. 441-455, 2003.

SAATCHI, S. S.; SOARES, J. V.; ALVES, D. S. **Mapping deforestation and land use in Amazon rainforest by using SIR-C imagery.** Remote Sensing of Environment, v. 59, n.2, p. 191-202, 1997.

SAATCHI, S. S.; NELSON, B.; PODEST, E.; HOLT, J. **Mapping land cover types in the Amazon Basin using 1 km JERS-1 mosaic.** International Journal of Remote Sensing, v. 21, n.6, p. 1201 - 1234, 2000.

SABINS JR, F. F. **Remote sensing: principles and interpretation.** 3. ed. New York: W.H. Freeman and Company, 1996. 494p.

SANT'ANNA, S. J. S. **Avaliação do desempenho de filtros redutores de "speckle" em imagens de radar de abertura sintética.** 1995. 209 p. (INPE-6125-TDI/586). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1995.

SANT'ANNA, S. J. S.; DUTRA, L. V.; FREITAS, C. C.; BINS, L. S.; GOMES, A. R.; MURA, J. C. Introdução ao processamento de imagens de radar. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis, **Anais...** São José dos Campos: INPE, 2007. p. 205. (INPE-14786-PUD/185).

SANTOS, J. R.; MURA, J. C.; PARADELLA, W. R.; DUTRA, L. V.; GONÇALVES, F. G. 2008. **Mapping recent deforestation in the Brazilian Amazon using simulated L-band MAPSAR images.** International Journal of Remote Sensing, v. 29, n. 16, p. 4879-4884.

SASSAGAWA, H.S.Y 1999. **Técnicas de Sensoriamento Remoto e Sistema de Informações Geográficas (SIG) para o estudo da Ocupação do Espaço Físico e dos Tipos Florestais da Reserva Extrativista Chico Mendes, Estado do Acre.** Dissertação de Mestrado em Sensoriamento Remoto. São José dos Campos: INPE, 185p.

SHIMABUKURO, M.T. (1996). **Avaliação de Classificadores Espectrais de Imagens Landsat-TM em Áreas Rurais Densamente Ocupadas: o caso da região de Brotas e Torrinhã.** Dissertação de Mestrado, Universidade Estadual de Campinas, Instituto de Biologia, Campinas, SP, 177p.

SHIMABUKURO, Y. E; AMARAL, S; AHERN, F. J.; PIETSCH, R. W. **Land cover classification from Radardat data of the Tapajós National Forest, Brazil.** Canadian Journal of Remote Sensing, v. 24, n. 4, 1998.

SHIMABUKURO, Y. E; NOVO, E.M.; PONZONI, F. J. 1998. **Índice de Vegetação e Imagens Fração Derivados do Modelo Linear de Mistura Espectral para o Monitoramento da Região do Pantanal.** Pesquisa Agropecuária Brasileira, 33: 1729-1737.

SILVA, W. F. **Imagens polarimétricas em banda L do SAR-R99B e do MAPSAR (simuladas) para distinguir culturas agrícolas.** 2007. 145 p. (INPE-14821-TDI/1261). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2007.

SIMARD, M.; SAATCHI, S. S.; DE GRANDI, G. **The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest.** IEEE Transactions on Geoscience and Remote Sensing v. 38, n.5, p. 2310-2321, 2000.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition.** 4. ed. San Diego: Academic Press, , 2006.

TOUZI, R.; LANDRY, R.; CHARBONNEAU, F. J. **Forest type discrimination using C band polarimetric SAR data.** Canadian Journal of Remote Sensing, v. 30, n. 3, p. 543- 551, 2004.

TOUZI, R.; BOERNER, W. M.; LEE, J. S.; LUENEBURG, E. **A review of polarimetry in the context of synthetic aperture radar: concepts and information extraction.** Canadian Journal of Remote Sensing, v. 30, n.3, p. 380-407, Jan 2004.

THIEL, C.; DREZET, P.; WEISE, C.; QUEGAN, S.; SCHUMULLIUS, C. **Radar remote sensing for the delineation of forest cover maps and the detection of deforestation.** Forestry, v. 79, n. 5, 2006.

TREITZ, P.; ROGAN, J. Remote sensing for mapping and monitoring land-cover and land-use change - an introduction. **Progress in Planning**, v. 61, p. 269-279, 2004.

TURNER, B. L; MEYER, W.B. Global land-use and land-cover change: An overview. In: Meyer W. e Turner, B. L. ed. **Changes in land use and land cover: a global perspective.** Cambridge: Cambridge University Press. p. 3-10, 1994.

ULABY, F.T.; BATLIVALA, P.P. **Optimum radar parameters for mapping soil moisture.** IEEE Transactions Geoscience Eletronics, v. 14, n. 2, p. 81-93, 1976.

ULABY, F.T.; MOORE, R.K.; FUNG, A.K. **Microwave remote sensing active and passive.** Washington: Addison-Wesley,. v.2, 1982.

ULABY, F.T.; ALLEN, C.T.; EGER, G.; KANEMASU, E. Relating the microwave backscattering coefficient to leaf area index. **Remote Sensing Environment.**, v.14, n.1-3, p. 113-133, Jan. 1984.

ULABY, F.T.; MORE, R.K.; FUNK, A.K. **Microwave remote sensing: active and**

passive. Reading, Addison-Wesley, 1986a. v.2. 360p.

VAN DER SANDEN, J. J. **Radar remote sensing to support tropical forest management**. Doctoral Thesis, Tropenbos-Guyana Series, 330 p.,1997.

VAN DER SANDEN, J. J.; HOEKMAN, D. H. **Potential of airborne radar to support the assessment of land cover in a tropical rain forest environment**. Remote Sensing of Environment, v. 68, n.1, p. 26-40, 1999.

Vapnik, V.; Cortes, C. **Support-Vector Networks**. Machine Learning, v. 20, p. 273-297, 1995.

VEIGA, R. Q. **Processador SAR com compensação de movimento para o SARSIVAM**. 2004, 92 p. Dissertação (Mestrado em Engenharia Eletrônica e Computação). Instituto Tecnológico da Aeronáutica (ITA), São José dos Campos, 2004.

VIEIRA, P. R. (1996). **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**, Dissertação de Mestrado, Instituto de Nacional de Pesquisas Espaciais. São José dos Campos.

WALKER, R. **Theorizing Land-Cover and Land-Use change: The case of tropical deforestation**. International Regional Science Review, v. 27, n.3. p. 247-270, 2004.

ZALOTI, O. D. J.; GONÇALVES, F. G.; FREITAS, C. C.; SANT'ANNA, S. J. S.; SANTOS, J. R. **Evaluating the potential of SAR-R99B L and X bands data for Amazon deforestation increment mapping**. In: IEEE International Geoscience and Remote Sensing Symposium, 2006, Denver, Colorado. **Proceedings...**Piscataway: IEEE, 2006. p. 2662-2665.