



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
Câmpus de Presidente Prudente

CRISTINA APARECIDA BENEDITTI

**Imagens multitemporais ALOS/PALSAR baseada em orientação
a objeto na discriminação da cobertura da terra**

Presidente Prudente

Agosto de 2010



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
Câmpus de Presidente Prudente

Imagens multitemporais ALOS/PALSAR baseada em orientação a objeto na discriminação da cobertura da terra

Dissertação submetido ao Programa de Pós-Graduação em Ciências Cartográficas da FCT/UNESP.

Mestranda: Cristina Aparecida Beneditti

Orientador: Prof. Dr. Nilton Nobuhiro Imai

Co-orientadora: PhD. Laura Hess

Presidente Prudente

Agosto de 2010

*A meus pais e minha irmã pelo incentivo,
apoio, amor e confiança.*

AGRADECIMENTOS

A Deus, pela força, sabedoria, coragem e conforto nos momentos em que só por minhas próprias forças não conseguiria prosseguir e vencer as dificuldades.

A JAXA EORC, a qual disponibilizou as imagens ALOS/PALSAR e ao Takeo Tadono da JAXA EORC por criar o PRISM DSM utilizado neste trabalho.

A JAXA Kyoto & Carbon Initiative, a qual neste contexto, em partes, esse trabalho foi realizado.

Ao professor Dr. Nilton Imai pela orientação, amizade e confiança depositada em mim para realizar esse trabalho. Além das horas discutindo os assuntos.

À PhD. Laura Hess pelos ensinamentos científicos e de vida, pela confiança, paciência e companheirismo principalmente no período que estive em São José dos Campos. Thank you very much!

À prof. Dra. Maria de Lourdes pela amizade, conversas, confiança e discussões relacionadas ao trabalho.

À Dra. Evelyn M.L.M. Novo pela atenção e preocupação enquanto estive no INPE e por proporcionar a parceria com a PhD Laura Hess.

A Madalena Niero do INPE pelas orientações, atenção, disponibilidade e ajuda sempre que precisei e na interação com a UNESP de Rio Claro.

Ao Adriano da UNESP de Rio Claro pela força e companheirismo nos trabalhos de campo e pelas longas conversas e filosofias sobre a vida durante nossos trajetos de campo.

Aos meus amigos da PPGCC que estiveram comigo durante esse mestrado rindo e chorando, claro que mais rindo do que chorando.

Aos colegas do INPE, Cleber, Arnaldo, Igor, Poly, Rodrigo, Haron, Maristela, Marcos, pelos ensinamentos e discussões que sempre me fizeram crescer.

Ao CNPq pela bolsa de mestrado e ao PROCAD/CAPES pelo auxílio financeiro para permanecer em São José dos Campos.

Enfim, agradeço a todos que de uma maneira ou de outra estiveram comigo e me ajudaram a chegar até aqui.

*“Coração me leva pelas suas asas,
semeando sonhos, desbravando
estradas...”*

(Pe Fabio de Melo)

RESUMO

Sensores ópticos são amplamente utilizados para mapeamento da cobertura da terra em escala local e pequenas regiões, com uma ampla variedade de aplicações, incluindo planejamento urbano, inventário agrícola e florestal, gerenciamento de bacias hidrográficas e monitoramento ambiental. Mapeamento de cobertura da terra com dados da banda L SAR tem focado primariamente em florestas e área úmidas de regiões tropical e boreal, com ênfase no monitoramento de desmatamento tropical e reflorestamento. No início de 2006, aquisições sistemáticas do ALOS PALSAR tem fornecido conjunto de dados multissazonais com alta resolução (12,5m), com potencial para substituir ou complementar os conjuntos de dados ópticos para mapeamento de cobertura da terra em regiões que a cobertura de nuvens é menos problemática, mas ainda um limitante para a variação sazonal da cobertura da terra. Este estudo avalia a utilização de dados PALSAR multitemporal, combinados com modelo digital de superfície (DSM) derivado do ALOS PRISM, para o mapeamento da cobertura da terra em uma região central do estado de São Paulo, Brasil. A área de estudo (22.5°S 47.8 °W) está situada na região oeste do reservatório de Barra Bonita, próximo a confluência dos rios Tietê e Piracicaba, com elevações variando entre 300 e 1000m. Os usos da terra dominante são agricultura (cana de açúcar, cítricas e gramíneas) e florestal (eucaliptos). A vegetação natural é restrita a vegetação riparia, mata na front da cuesta e macrofitas aquáticas sazonais. Áreas urbanas presente na região são São Pedro e Aguas de São Pedro. Duas cenas PALSAR no modo *Fine-Beam Single-polarization* (FBS) (08 de abril de 2008 e 09 de janeiro de 2009, reamostradas de 6,25m para 12,5m) e uma cena no modo *Fine-Beam Dual-polarization* (FBD) (09 de julho de 2008; 12,5m) foram co-registradas com um DSM PRISM (2,5m, reamostrados para 12,5m) gerado usando o programa DSM and Ortho Image Generation ALOS PRISM (DOGS-AP) pela JAXA, e um mapa derivado de declividade. Foram extraídas amostras de treinamento nas diferentes datas para as classes reservatórios, rios e lagos, vegetação úmida, eucaliptos, cana de açúcar, cítricas, gramíneas, vegetação natural e área urbana, e usou para o desenvolvimento de um conjunto de regras para os objetos criados por uma segmentação multidata e multiresolução. As características dos objetos utilizados para a classificação foi o retroespalhamento médio em cada data, a diferença entre as datas, declividade e aspecto. As características de relação incluíram a borda relativa. A acurácia da classificação foi avaliada usando a imagem PRISM ortoretificada de 2,5m e observações de campo. A acurácia global foi de 85,6% e o índice Kappa foi de 0,81. Os resultados indicaram boa acurácia para a maioria das classes e potencial para mapeamento da extensão da cana de açúcar usando PALSAR.

ABSTRACT

Optical sensors are widely used for land cover mapping at local and small region scales, for a wide variety of applications including urban planning, forest and crop inventory, watershed management, and environmental monitoring. Land cover mapping with L-band SAR data has focused primarily on forest and wetland areas in tropical and boreal regions, with particular emphasis on monitoring tropical deforestation and regrowth. Beginning in 2006, systematic acquisitions of ALOS PALSAR have provided multi-season, near-global data sets at high (12.5 m) resolution, with the potential to substitute for or complement optical data sets for land cover mapping in regions where cloud cover is less problematic, but still limiting for seasonally varying land cover. This study evaluates the utility of multi-temporal PALSAR data, combined with a digital surface model (DSM) derived from ALOS PRISM, for land cover mapping at a site in central São Paulo state, Brazil. The study area (22.5°S 47.8°W) is situated at the west end of the Barra Bonita Reservoir, at the entrance point of the Tietê River, with elevations ranging from about 300 to 1000 m. Dominant land uses are agriculture (sugar cane, citrus, pasture) and forestry (eucalyptus). Natural vegetation is largely restricted to riparian forest, forests on steep slopes, and seasonal aquatic macrophytes. Urban areas include the cities of São Pedro and Águas de São Pedro. Two PALSAR Fine-Beam Single-polarization (FBS) mode scenes (8 April 2008 and 9 January 2009; resampled from 6.25 m to 12.5 m pixel dimensions) and one Fine-Beam Dual-polarization (FBD) mode scene (9 July 2008; 12.5 m) were co-registered to a PRISM DSM (2.5 m, resampled to 12.5 m) generated using the DSM and Ortho Image Generation ALOS PRISM (DOGS-AP) software from JAXA, and to a derived slope map. Multi-date training statistics were extracted for the classes Reservoir, river and lake, Aquatic Vegetation, Pasture, Sugar Cane, Natural Forest, Eucalyptus and Citrus Plantation and Urban, and used to develop rules sets for image objects created by multi-date, multi-resolution segmentation. Object features used for classification were backscattering single-date mean, backscattering difference between dates, slope, and aspect. Relational features included relative border. Classification accuracy is being assessed using a 2.5 m PRISM ortho image. Global accuracy was 85.6% and Kappa index was 0.81. The validation based on field observations indicates good accuracies for most classes, and the potential for mapping sugar cane extent using PALSAR.

LISTA DE FIGURAS

Figura 1: Região de microondas no espectro eletromagnético.....	17
Figura 2: Funcionamento básico dos radares imageadores.	18
Figura 3- Sistema de polarização da onda eletromagnética. Fonte JENSEN(2000).	20
Figura 4: Exemplo dos tipos de reflexão nos alvos.....	21
Figura 5- Espalhamento volumétrico	21
Figura 6: Efeito de encurtamento de rampa.	23
Figura 7: Efeito da inversão.	23
Figura 8: Efeito de sombreamento.	24
Figura 9- Hierarquia de objetos. Cada objeto está conectado com seu vizinho, seu superobjeto e seu subobjeto. (DEFINIENS, 2007).	29
Figura 10: Localização da área de estudo.	36
Figura 11: Precipitação na região de estudo durante o período próximo aos meses de aquisição dos dados PALSAR.	37
Figura 12: Fluxograma do procedimento metodológico.	39
Figura 13: Pontos de coleta de dados planimétricos e altimétricos.....	40
Figura 14: Conjunto de pontos utilizados para a avaliação da classificação.....	44
Figura 15: a) DSM utilizado para a correção do terreno; b) composição colorida da imagem PALSAR.	46
Figura 16: Hierarquia das classes mapeadas.	47
Figura 17: Ciclo da cana de açúcar.	50
Figura 18: Exemplos de cana de açúcar encontrada na área de estudo.	51
Figura 19: Plantação de cana de açúcar em diferentes estágios.	52
Figura 20: Exemplo de reservatório, rios e lagos.	53
Figura 21: Atributo de forma geométrica densidade (<i>density</i>).	54
Figura 22: Região de gramínea dentro da área de estudo.....	54
Figura 23: Regiões de gramínea na área de estudo.	55
Figura 24: Região de gramínea na vertente voltada para o imageamento(A) e na vertente oposta (B).	56
Figura 25: a) mata natural em propriedade; b) mata natural em zona ripária; c) mata natural na cuesta	57
Figura 26: Retroespalhamento em mata natural nas polarizações HH e HV.	58
Figura 27: Vegetação em área úmida na região de estudo.	59
Figura 28: Retroespalhamento da vegetação úmida nas polarizações HH.....	60
Figura 29: Plantação de eucalipto presente na área de estudo.....	61
Figura 30: Diferença entre eucalipto e mata.	61
Figura 31: Plantação de eucalipto em diferentes situações de corte. A) cortado entre julho de 2008 e janeiro de 2009; B) estava sendo cortado em janeiro de 2009; C) não foi cortado.....	62
Figura 32: Eucaliptos em diferentes estagio de crescimento.....	63
Figura 33: Retroespalhamento das cítricas nas polarizações HH e HV durante o período de análise.	64
Figura 34: A) bairro com espaçamento grande entre as casas. B) região central da área urbana	65
Figura 35: BOXPLOT do brilho médio do retroespalhamento nos objetos amostrais de cada classe, permitindo a divisão em três grupos amostrais indicados – Brilhante, Médio, Escuro.....	67
Figura 36: Grupos abstratos da classificação.	68
Figura 37: BOXPLOT de cada polarização dos objetos amostrais para cada classe a ser mapeada.	69
Figura 38: BOXPLOT das classes cana de açúcar, cítricas e eucaliptos mostrando suas variações no tempo.....	70

Figura 39: A) Exemplo do atributo aspecto; B) Verde e azul são regiões que não estão voltadas para o imageamento- aspecto não está entre 171 e 351.	70
Figura 40: Regiões do grupo brilhante.	71
Figura 41: Pontos de vista da região da cuesta. As setas azuis indicam a região voltada para a orientação do imageamento e as setas vermelhas a região oposta.	72
Figura 42: Regiões de mata na cuesta no lado esquerdo e de área urbana no lado direito da imagem .	73
Figura 43: Mapeamento da classe reservatórios, rios e lagos	74
Figura 44: Exemplo do resultado da classificação da gramínea.....	75
Figura 45: Resultado parcial da classificação da vegetação de área úmida.	75
Figura 46: Mata natural na vertente oposta a linha de imageamento.	76
Figura 47: Exemplo da classificação da mata natural	77
Figura 48: Classificação do eucalipto que foi cortado em janeiro de 2009.....	77
Figura 49: Classificação de eucalipto mais jovem.	78
Figura 50: Região em que o eucalipto confunde-se com cítricas.	78
Figura 51: Exemplos da classificação da cana de açúcar.	79
Figura 52: A) Exemplo da classificação de cítricas; B) exemplo da classificação de cana de açúcar como cítricas.	80
Figura 53: Resultado final após a aplicação de todas as regras de classificação e refinamento.....	82
Figura 54: Classificação com ausência do <i>speckle</i>	83

LISTA DE TABELAS

Tabela 1: Exemplo de matriz de confusão	31
Tabela 2: Matriz de confusão com a exatidão global.	33
Tabela 3: Características do sensor PALSAR/ALOS.	35
Tabela 4: Características do sensor PRISM.	35
Tabela 5 : Descrição das imagens PALSAR utilizados na pesquisa	38
Tabela 6: Denominação das polarizações	42
Tabela 7: Acurácia planimétrica e altimétrica.....	45
Tabela 8: Testes dos parâmetros de segmentação.	48
Tabela 9: Parâmetros para a criação dos níveis de segmentação.	49
Tabela 10: Resumo da caracterização das classes a serem mapeadas.....	66
Tabela 11: Matriz de erro da classificação final.....	84

Sumário

1. INTRODUÇÃO	13
1.1. Objetivo.....	14
2. ANÁLISE ORIENTADA A OBJETO DE IMAGENS SAR.....	15
2.1. Sensoriamento remoto e cobertura da terra	15
2.2. Radar- <i>Radio Detection And Ranging</i>	16
2.3. Análise orientada a objeto.....	25
2.4. Segmentação multiresolução (<i>Multiresolution Segmentation</i>).....	27
2.5. Classificação orientada a objeto	29
3. AVALIAÇÃO DE CLASSIFICAÇÃO	31
4. PLATAFORMA ALOS	34
4.1. PALSAR (<i>Phased Array L-band Synthetic Aperture Radar</i>)	34
4.2. PRISM (<i>Panchromatic Remote-sensing Instrument for Stereo Mapping</i>).....	35
5. ÁREA DE ESTUDO	36
6. MATERIAL UTILIZADO E PROCEDIMENTOS METODOLÓGICOS.....	38
6.1. Material utilizado.....	38
6.2. Procedimentos metodológicos.....	39
7. RESULTADOS E DISCUSSÕES	45
7.1. Correções do terreno	45
7.2. Definição das classes	46
7.3. Segmentação	47
7.4. Classificação	50
7.5. Avaliação da classificação	84
8. CONCLUSÕES E RECOMENDAÇÕES	86
REFERÊNCIAS BIBLIOGRÁFICAS	87
APÊNDICE A- Regras para a classificação das diferentes coberturas da terra.	91

1. INTRODUÇÃO

A informação de cobertura da terra é um importante fator para gestão de uma região, pois fornece subsídios para a implantação de projetos visando a sustentabilidade e o crescimento da região. Essas informações são apresentadas em documentos que mapeiam a presença das coberturas naturais, agrícolas e zonas urbanas que podem contribuir para os impactos ambientais tanto no meio físico diminuindo a produtividade e disponibilidade de áreas úteis para o plantio como, por exemplo, as erosões, quanto no meio aquático provocando alterações na qualidade da água inviabilizando o uso para determinadas atividades.

Neste sentido, muitos estudos sobre mapeamento da cobertura terra têm sido desenvolvidos com o uso de imagens de sensores ópticos, porém esses sensores têm sua capacidade limitada pela presença de nuvens durante o imageamento principalmente em períodos de grande nebulosidade o que dificulta o monitoramento e a análise temporal da região. Desta forma, uma alternativa é a utilização de sistemas de RADAR (*Radio Detection and Ranging*), que operam na faixa de microondas do espectro eletromagnético. Esses sistemas possuem a grande vantagem de serem capazes de adquirir dados independentemente da iluminação solar e de praticamente não serem influenciados pelas condições atmosféricas.

Uma limitação desses sistemas com relação a classificação das imagens é a presença de um ruído inerente ao sistema, chamado *speckle*, o qual introduz um aspecto granuloso às imagens. Devido a grande variância introduzida pelo ruído *speckle* os algoritmos de classificação baseados apenas nos dados puramente espectrais de um *pixel* isolado são pouco eficientes, quando usados em imagens de RADAR. Sendo assim, as abordagens de análise de informações de uma região formada por um grupo de *pixels* semelhantes em contraposição à análise de apenas um pixel minimizam esse ruído característico desses sistemas. Dentre essas abordagens está a orientada a objetos, cuja análise permite utilizar não só as informações espectrais dos segmentos, mas também permite a inserção do conhecimento do intérprete e a utilização de parâmetros de cor, forma, textura e contexto na classificação das imagens.

Neste contexto, a hipótese deste trabalho foi que a análise orientada a objetos aplicada em imagens de radar de abertura sintética- SAR (*Synthetic Aperture Radar*), multitemporais em banda L, polarização dual (HH e HV) seja adequada para a discriminação da cobertura da terra em regiões com complexo padrão espacial de diferentes tipos de uso da terra.

Nessa hipótese está implícito que as variações sazonais das coberturas da terra, registradas no conjunto de imagens temporais, tem papel relevante na abordagem de classificação adotada.

1.1. Objetivo

Estabelecer uma metodologia de classificação baseada no conhecimento aplicada às imagens ALOS/PALSAR com polarização dual (HH e HV) através da especificação e caracterização dos diferentes tipos de cobertura da terra segundo suas variações temporais, além da investigação e estabelecimento de parâmetros para a segmentação das imagens em uso.

2. ANÁLISE ORIENTADA A OBJETO DE IMAGENS SAR

2.1. Sensoriamento remoto e cobertura da terra

A informação de cobertura da terra é essencial na elaboração de uma melhor política para o desenvolvimento de uma região. São utilizados em diagnósticos ambientais, inventários hídricos, controle de inundações, identificação de áreas com processos erosivos avançados, dentre outros. É um meio importante de ligação entre informações dos meios biofísico e socioeconômico.

Essa informação é representada através de mapas de uso e cobertura da terra, porém é fundamental fazer a definição de uso e de cobertura da terra, pois em muitas classificações e legendas esses termos são confundidos. Sendo assim, entende-se por “cobertura da terra” toda matéria (bio)física sobre a superfície terrestre. Além disso, é discutido se superfícies aquáticas são consideradas cobertura da terra, no entanto, na prática, a comunidade científica geralmente a inclui como “cobertura da terra” (DI GREGORIO, 2004). Deste modo, neste trabalho, também são consideradas como uma cobertura da terra.

O termo uso da terra refere-se às atividades que as pessoas desenvolvem em certo tipo de cobertura da terra, mantendo ou modificando-o para obter benefícios. Um exemplo é a gramínea, que é uma cobertura da terra, mas que pode ter diferentes usos, como ser uma pastagem ou então um campo de futebol. Este trabalho foi desenvolvido com o enfoque na cobertura da terra e não no uso.

O levantamento dos dados de cobertura da terra tem sido feito tradicionalmente a partir de fotografias aéreas, trabalhos de campo e, mais recentemente, através de imagens orbitais, as quais tem se tornado cada vez mais importante, pois permitem a aquisição de dados de forma global, confiável, rápida e sistemática (ROSA, 2003). Juntamente com a disponibilidade histórica de dados de sensoriamento remoto, a redução de custo dos dados e maior resolução das plataformas de satélite, as imagens orbitais passaram a se constituir em ferramenta importante para mapeamentos (ROGAN; CHEN, 2004).

Deste modo, muitos trabalhos têm sido desenvolvidos com o uso dessas imagens, principalmente ópticas. Aguiar et al (2009) analisou a expansão da cana de açúcar no estado de São Paulo entre as safras 2003/2004 e 2008/2009 com o uso de imagens do sensor TM (*Thematic Mapper*) a bordo do satélite Landsat-5, imagens do sensor ETM+ (*Enhanced Thematic Mapper Plus*) a bordo do Landsat-7 e como alternativa às imagens TM com cobertura de nuvens, foram utilizadas imagens do sensor CCD (*High Resolution Change*

Coupled Device Camera) a bordo dos satélites CBERS-2 e CBERS-2B. Galford et al. (2005), usando dados EVI/MODIS - produtos MOD13Q1 - analisaram padrões de manejo sobre áreas agrícolas no estado do Mato Grosso.

Apesar de as imagens dos sensores ópticos serem de mais fácil interpretação e possuírem diversas técnicas de processamento de imagens que facilite esse processo, elas são extremamente vulneráveis à visibilidade atmosférica, ou seja, tem como limitante a presença de nuvens durante o imageamento. Isso ocorre principalmente em períodos chuvosos, o que dificulta uma análise temporal de uma dada região. Desta forma, uma solução alternativa é a utilização de outros sensores operando em diferentes faixas do espectro eletromagnético, entre elas, a faixa das microondas. Esses sensores se mostram uma ferramenta útil no processo de caracterização, inventário e monitoramento florestal e agrícola, pois são quase independentes das condições atmosféricas e podem produzir assim um conjunto de dados multitemporais confiáveis.

Alguns estudos apresentam que há melhora da exatidão da classificação com o uso de imagens SAR multitemporais. Brisco e Braown (1995) mostraram que a acurácia da classificação baseada em quatro aquisições de imagens SAR aumentou em 24% comparado com os resultados realizados com duas imagens. Blaes et al. (2005) compararam a acurácia de vários conjuntos de dados multitemporais ERS. Dependendo do número de imagens a acurácia aumentava significativamente chegando a um aumento de 25%. Waske e Braun (2009) alcançaram quase 84% de acurácia global em áreas rurais com o uso de dados SAR multitemporais. Desta forma, utilizar dados SAR multitemporais torna-se mais relevantes quando a região de estudo engloba áreas agrícolas que apresentam mudanças sazonais.

2.2. Radar- *Radio Detection And Ranging*¹

Antes de discorrer a respeito das imagens de radar, é preciso entender onde está a banda de microondas e como as imagens são formadas, para só então entender como os diversos fatores podem influenciar na sua interpretação.

Os sistemas de RADAR operam em uma faixa restrita do espectro eletromagnético, denominada microondas. Essa faixa é dividida em bandas, designadas por letras, como apresentado na Figura 1.

¹ *Radio Detection And Ranging*: detecção e localização por meio de ondas de rádio




Figura 1: Região de microondas no espectro eletromagnético.

Os sensores que operam nesta faixa possuem a grande vantagem de serem capazes de adquirir dados independentemente da iluminação solar e de serem pouco influenciados pelas condições atmosféricas, uma vez que a transmitância atmosférica é praticamente total para a faixa das microondas. Segundo dados apresentados em Elachi (1987) a porcentagem de transmissão atmosférica nos diferentes comprimentos de onda para um sensor colocado no zênite está em torno de 80%, na região do visível, enquanto na região das microondas, ela atinge praticamente 100%, demonstrando que a atmosfera não afeta com a mesma intensidade sua interação com os alvos da superfície terrestre.

No sensoriamento remoto por microondas existem dois tipos de sistemas: os ativos (radares) e os passivos (radiômetros). O termo ativo refere-se ao sensor que possui sua própria fonte de energia ou iluminação. Já o termo passivo refere-se aos radiômetros de microondas que captam níveis baixos de energia emitidos ou refletidos por alvos terrestres (LILLESAND; KIEFER, 1987). Os sistemas de RADAR podem ser agrupados em não imageadores e imageadores, sendo que para o sensoriamento remoto os imageadores de visada lateral de abertura sintética (SAR) são os mais utilizados.

O princípio básico de funcionamento dos radares imageadores consiste na emissão da radiação eletromagnética direcionada à superfície terrestre e na gravação da intensidade e do tempo de retorno da energia retroespalhada pelo alvo na superfície à medida que o sensor se desloca. (ULABY et al., 1986). Os radares utilizados em sensoriamento remoto emitem pulsos que se propagam à velocidade da luz. Quando um objeto é iluminado pelo feixe do

radar, ele reflete parte da energia incidente em todas as direções. Essa reflexão é denominada de espalhamento. Na maioria dos radares, as direções de incidência e reflexão são as mesmas porque a fonte e o detector estão muito próximos um do outro. Nesse caso o sinal, modificado pelos alvos, é chamado de retroespalhamento (Figura 2). Esses pulsos são de forma que o sinal de retorno traz informações sobre esses alvos. A informação do alvo é transportada através de ondas eletromagnéticas que são definidas pela direção de propagação, amplitude, comprimento de onda (λ) ou frequência, polarização e fase.




Figura 2: Funcionamento básico dos radares imageadores.

Esse sinal é estruturado na forma de um dado complexo, decomposto em duas partes: sinal em fase (I: *In Phase*) e sinal em quadratura de fase (Q: *Quadrature*). A partir desse dado podem ser obtidos em amplitude, dado por $A = \sqrt{I^2 + Q^2}$ e em intensidade ($I = A^2$). A normalização dessa refletividade média da amostra do alvo pela unidade de área no plano horizontal é chamado de coeficiente de retroespalhamento, dado por sigma zero (σ_0) (ULABY et al., 1981). Essa normalização é importante para que os dados possam ser comparados e utilizados como referencia para outras pesquisas. A conversão de amplitude para sigma zero é realizada aplicando a equação (SHIMADA et al., 2006): $\sigma^0 = 10 \cdot \log_{10} (DN^2) + CF$, onde DN é o nível de cinza (*Digital Number*) da imagem em amplitude e CF, o fator de conversão para o dado em amplitude. Esse coeficiente é dependente da polarização e do período em que o dado foi obtido.

O comportamento do retroespalhamento é afetado por dois conjuntos de variáveis: as relacionadas ao sistema radar (frequência, polarização, ângulo de incidência e resolução) e as ligadas ao alvo (rugosidade, constante dielétrica e geometria).

A frequência e o ângulo de incidência local da onda transmitida determinam se uma superfície aparece mais rugosa ou mais lisa. Com o aumento do comprimento de onda

(λ) a rugosidade da superfície diminui, uma vez que a rugosidade relativa é dada por $k = 2\pi / \lambda$. Além da frequência o ângulo de incidência local também exerce um papel importante para definir a condição de rugosidade de uma superfície. A superfície aparece mais rugosa quando o ângulo de incidência local é maior e menos rugosa para ângulos menores. Considerando um comprimento de onda constante e o ângulo de incidência local fixo, a interação da onda eletromagnética transmitida com a superfície de diferentes condições de rugosidade pode ser em geral considerada como rugosa a superfície com espalhamento mais difuso e suave com espalhamento mais direcional (HAJNSEK; PAPATHANASSIOU, 2005).

A polarização de uma onda eletromagnética descreve a inclinação do plano de oscilação do campo elétrico (E) em relação ao plano de propagação da onda, em função do tempo. A energia não polarizada vibra em todas as direções possíveis perpendiculares à direção de propagação. As antenas de radar enviam e recebem a energia polarizada, ou seja, o pulso é filtrado para que as vibrações do campo elétrico da onda ocorram somente em um único plano perpendicular à direção de propagação. Essa polarização pode ser vertical (V) ou horizontal (H), conforme apresentado na Figura 3. A energia retroespalhada retorna ao sensor, onde passa novamente por um filtro (H ou V). Existem quatro combinações lineares possíveis de polarização: HH, VV, HV e VH. As polarizações HH e VV são chamadas de polarizações lineares paralelas horizontal e vertical respectivamente. A primeira letra refere-se à polarização da radiação transmitida pela antena e a segunda à polarização recebida. As polarizações HV e VH são chamadas de polarizações cruzadas.




Figura 3- Sistema de polarização da onda eletromagnética. Fonte JENSEN(2000).

Resolução espacial é a menor distância em que se pode distinguir dois objetos e depende da distância entre os centros de dois ecos pontuais. A resolução em radar é definida em duas direções: paralela e perpendicular à direção de voo. A primeira é chamada de resolução em azimuth e é definida pelo processamento do sinal independentemente do tamanho da antena em sistemas SAR; a segunda é definida como resolução em range e é proporcional ao comprimento do pulso da onda.

A rugosidade é uma importante característica relacionada ao alvo que influencia na imagem de radar. A rugosidade superficial influencia no espalhamento da energia de microondas e, consequentemente, o brilho dos alvos nas imagens de radar. As superfícies lisas e horizontais espalham quase toda a energia incidente em direção oposta ao sistema de radar e são chamadas especulares. As superfícies especulares, tais como águas calmas ou rodovias pavimentadas, aparecem escuras em imagens de radar. As microondas que incidem sobre uma superfície rugosa são espalhadas em várias direções. Esse fenômeno é conhecido como espalhamento difuso ou distribuído. As superfícies com vegetação que são mais rugosas

causam espalhamento difuso e resultam em uma tonalidade mais brilhante em imagens de radar (Figura 4).




Figura 4: Exemplo dos tipos de reflexão nos alvos.

O espalhamento volumétrico está relacionado ao processo de despolarização da onda eletromagnética e é observado nas polarizações cruzadas (HV, VH). Ele ocorre em cobertura vegetal de uma floresta ou cultura agrícola como cítricas onde aumenta o número de espalhamento e quando o volume desses espalhamentos aumenta muito o sinal satura. Esse tipo de espalhamento também pode ocorrer em camadas de solo muito seco, areia ou gelo. A intensidade do espalhamento volumétrico depende das propriedades físicas do meio (sobretudo das variações na constante dielétrica) e das características do radar (comprimento de onda, polarização e ângulo de incidência) (HENDERSON, 1998). Esse espalhamento é ilustrado na Figura 5.




Figura 5- Espalhamento volumétrico

A constante dielétrica é a capacidade que um material (vegetação, solo, água, etc...) tem em conduzir energia elétrica e causa influência direta na capacidade do material em absorver, refletir e transmitir energia na faixa de microondas. O parâmetro que influencia

mais significativamente essa variável é o conteúdo de umidade, sendo assim, um solo ou uma vegetação mais úmida terá um impacto significativo na quantidade de energia retroespalhada (MIKHAIL et al., 2001). Solos úmidos refletem mais energia de radar do que solos secos que absorvem mais a onda de radar, dependendo da constante dielétrica do material que compõe o solo. Ou seja, o brilho da imagem da maioria da vegetação e superfícies naturais, aumenta com o aumento do seu teor de umidade.

Segundo Dobson et al. (1995) as propriedades geométricas controlam a distribuição espacial do espalhamento, determinando em que direção do espaço tridimensional o espalhamento se dá preferencialmente. Por isso o tamanho dos difusores ou das partes das plantas é muito importante no estudo das relações do retroespalhamento. Algumas dessas características importantes são altura, forma, orientação em relação à onda incidente, espaçamento e direção de plantio entre outras.

Tendo em vista alguns fatores que influenciam no retroespalhamento do sinal, é possível concluir que as imagens provenientes desse tipo de sistema não são simples. Elas são formadas por uma interferência coerente entre os difusores que formam cada *pixel* da imagem. Como cada elemento de resolução é composto por um grande número de difusores, o sinal de retorno resulta da soma coerente do sinal elementar retornado por cada um dos elementos difusores. Esse processo causa flutuações aleatórias ou interferências que dão um aspecto granuloso característico às imagens SAR, o qual é conhecido como ruído *speckle*. Assim, torna-se difícil determinar se as variações no retroespalhamento para *pixels* homogêneos, ou seja, *pixels* com valores digitais próximos são atribuídos às características do alvo ou ao ruído *speckle* (HENDERSON, 1998).

Além das variáveis descritas acima que afetam o retroespalhamento as imagens SAR sofrem efeitos de deslocamento do relevo devido a geometria de aquisição do sensor que necessitam ser corrigidas. Essas distorções ocorrem de maneira diferente daqueles observados em imagens ópticas. Enquanto que nas imagens de radar as estruturas verticais no terreno são deslocadas em direção ao sensor, em imagens ópticas, o deslocamento ocorre inversamente (no caso de imagens ópticas verticais, o deslocamento ocorre radialmente, do centro para as bordas da imagem) (MATHER, 1987; CRÓSTA, 1992; RICHARDS, 1999). Esses efeitos geométricos de radar são o encurtamento de rampa (*foreshortening*), a inversão (*layover*) e o sombreamento.

O encurtamento de rampa é a aparência de compressão das feições topográficas da cena. Esse deslocamento horizontal é resultado da pequena diferença entre os ângulos de incidência e o ângulo de inclinação. A Figura 6 mostra essa distorção.




Figura 6: Efeito de encurtamento de rampa.

A inversão é um caso extremo de encurtamento de rampa e ocorre quando o ângulo de incidência é menor do que a inclinação da encosta (Figura 7). Isso faz com que o topo da montanha seja mapeado “sobre” a encosta precedente.




Figura 7: Efeito da inversão.

O sombreamento de radar indica a presença de áreas no terreno que não são iluminadas pelo radar devido à geometria de visada e ao relevo. Como nenhum sinal retroespalhado é recebido, as áreas com sombreamento de radar aparecem com tonalidade muito escura nas imagens. Essa distorção é mais comum em terrenos íngremes, imageados com ângulos de incidência grandes (Figura 8).




Figura 8: Efeito de sombreamento.

Para corrigir esses deslocamentos de relevo na imagem, aplica-se uma correção geométrica. A correção geométrica tem a função de reorganizar os “pixels” da imagem em relação a um determinado sistema de projeção cartográfica.

Existe uma grande quantidade de fatores envolvidos na análise, interpretação e classificação das imagens SAR que influenciam a geração de produtos como, por exemplo, mapas de cobertura da terra a partir desses dados. Apesar de a interpretação de imagens SAR utilizar dos mesmos elementos de reconhecimento empregados na interpretação de fotografias aéreas e ópticas como tonalidade, textura, forma, tamanho, padrão e sombra, ressaltando que os elementos de imagens SAR são resultantes do retroespalhamento da onda de radar e não da reflectância da luz solar, é necessário um sólido conhecimento dos processos de interação da radiação de microondas com os diferentes alvos e das propriedades das imagens SAR juntamente com o aperfeiçoamento de metodologias de classificação para a obtenção de um bom produto final.

Os algoritmos de classificação baseados apenas nos dados puramente espectrais de um *pixel* isolado são pouco eficientes, quando usados em imagens SAR, em função da grande variância introduzida pelo ruído *speckle*. Desta forma, abordagens que analisam regiões, não só o *pixel*, que incluem atributos espaciais e de contexto espacial e temporal além dos espectrais, no processo de classificação dos dados começam a serem aperfeiçoadas e aplicadas em imagens SAR. A abordagem orientada a objetos permite a representação e aplicação do conhecimento do analista e a utilização de parâmetros de cor, forma, textura e relações de vizinhança na classificação de imagens (RIBEIRO et al. 2002). Com isso pode neutralizar algumas limitações do sensor e gerar resultados com melhor acurácia em comparação aos métodos baseados somente em *pixel* (DESCLEE et al., 2006).

2.3. Análise orientada a objeto

O conhecimento a priori desempenha um papel chave no processo de interpretação de imagens, adicionando informações importantes dentro do sensoriamento remoto (CAMPBELL, 2002). O cérebro humano tem a capacidade natural de interpretar rico conteúdo disponível em uma cena e pode intuitivamente identificar objetos como carro, casas, ruas, culturas agrícolas e muitas outras características, dividindo a imagem em vários objetos e usando propriedades como forma, textura, cor, contexto para entender a cena. Isso se deve à potencialidade do cérebro humano de explorar instantaneamente o conhecimento já armazenado e converte-lo em poderosas regras de interpretação de imagens. A abordagem orientada a objetos parte do princípio de tentar simular esse processo humano de interpretação (NAVULUR, 2006).

O princípio da análise de imagens orientada a objeto (*Object Based Image Analysis- OBIA*) consiste em representar uma cena com conteúdo complexo, de modo que a realidade imageada seja a descrita da melhor maneira possível e o máximo de conteúdo seja entendido, extraído e transmitido para os usuários. O desafio está em representar o conhecimento de maneira explícita, à semelhança de como o cérebro humano trabalha a informação em vários níveis, relacionando os objetos identificados com facilidade e entendendo o conteúdo complexo da cena rapidamente. Desta maneira, o OBIA utiliza conceitos de pensamento espacial influenciado pela psicologia cognitiva (LANG, 2008).

Em análise orientada a objeto o “objeto” é o elemento metodológico central e objeto de investigação. Para a criação desses objetos, são aplicadas técnicas de segmentação

de imagem. Esse processo consiste em agrupar os *pixels* de uma imagem em regiões que são homogêneas em relação às características espectrais e espaciais (RYHERD E WOODCOCK, 1996). Se essas regiões atendem aos quesitos de homogeneidade, tornam-se objetos da imagem. Os critérios para a definição de regiões são estabelecidos com base na experiência do interprete. Esses objetos formados podem estar relacionados diretamente com objetos do mundo real, diferentemente de *pixels* que dificilmente serão associados a elementos reais.

Um dos métodos utilizados para a formação dos objetos na segmentação de imagem é o crescimento por regiões. Essa técnica implica em agregar *pixels* a partir de um conjunto de “sementes”. A partir dessas sementes, as regiões vão crescendo e fundindo-se com os *pixels* vizinhos até que os parâmetros definidos pelas regras de homogeneidade sejam atingidos. A diferença entre os valores dos atributos de duas regiões é calculada e testada em relação a um limiar máximo de homogeneidade fornecido pelo usuário; se o valor verificado for menor que o limiar estabelecido, as regiões são agrupadas. Esse processo continua até que toda a imagem seja segmentada (FONSECA et al., 2000). Esses objetos contêm informações sobre suas características espectrais, forma, posição e textura, além de informações de sua vizinhança, importantes na classificação contextual.

Há alguns algoritmos utilizados para a segmentação de imagens ópticas que estão sendo aplicados em imagens SAR, como o algoritmo implementado no Sistema de Processamento de Informações Georeferenciada (SPRING) desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), e os resultados têm sido satisfatórios (HESS et al., 2003, GENOVEZ et al., 2009). Outro algoritmo com o mesmo objetivo de segmentação é o *MultiSeg*, desenvolvido por Sousa (2005). Ele é um segmentador hierárquico, multi-nível e multi-modelo e trabalha com imagens em uma banda ou multi-bandas. Apesar de esse segmentador apresentar bons resultados (SCOFIELD et al., 2009) ainda está sendo aprimorado. Os dois algoritmos citados não permitem acessar e utilizar diferentes níveis de segmentação, o que é importante para uma análise mais detalhada da imagem.

Um programa que permite a utilização de multiníveis tanto na segmentação quanto na classificação é o *eCognition Developer* desenvolvido pela Definiens de Munique, Alemanha. Os conceitos enunciados a respeito de segmentação e classificação orientada a objetos serão baseados nos algoritmos presentes neste programa, o qual foi utilizado nesta pesquisa.

2.4. Segmentação multiresolução (*Multiresolution Segmentation*)

Esse é um algoritmo de segmentação baseado em crescimento por regiões do tipo *bottom-up*, ou seja, agregar objetos menores, podendo iniciar com um pixel, para criar objetos maiores. Esse algoritmo, localmente, minimiza a heterogeneidade média dos objetos da imagem e maximiza sua respectiva homogeneidade. O processo de fusão dos *pixels* ou dos objetos existentes com seus vizinhos é feito baseado no critério de homogeneidade o qual é a combinação de outros dois critérios: o espectral e o de forma (DEFINIENS, 2007).

O critério de homogeneidade desse algoritmo descrito por Benz et.al., 2004, mede como é a homogeneidade ou a heterogeneidade interna do objeto imagem. Isso é calculado como a combinação das propriedades de cor e forma do objeto da imagem. A heterogeneidade é dada por f .

$$f = w_{cor} \cdot \Delta h_{cor} + w_{forma} \cdot \Delta h_{forma} ,$$

$$w_{cor} \in [0,1], w_{forma} \in [0,1], w_{cor} + w_{forma} = 1$$

em que, w_{cor} e w_{forma} são os parâmetros de peso que vão permitir a variação do critério de heterogeneidade de acordo com a aplicação desejada.

A heterogeneidade espectral permite adicionar peso para os diferentes canais e a diferença na heterogeneidade espectral, Δh_{cor} , é definido por:

$$\Delta h_{cor} = \sum_c w_c (n_{fund} \cdot \sigma_{c,fund} - (n_{obj_1} \cdot \sigma_{c,obj_1} + n_{obj_2} \cdot \sigma_{c,obj_2}))$$

Sendo, n_{fund} o número de *pixels* no objeto fusionado; n_{obj_1} o número de *pixels* no objeto 1; n_{obj_2} o número de *pixels* no objeto 2; $\sigma_{c,fund}$ o desvio padrão no objeto fusionado do canal c ; σ_{c,obj_1} o desvio padrão no objeto 1 do canal c ; σ_{c,obj_2} o desvio padrão no objeto 2 do canal c .

O critério de heterogeneidade da forma, Δh_{forma} , descreve a melhoria da forma com relação à suavidade e a compacidade da forma do objeto.

$$\Delta h_{forma} = w_{comp} \cdot \Delta h_{comp} + w_{suav} \cdot \Delta h_{suav}$$

sendo,

$$\Delta h_{suav} = n_{fund} \cdot \frac{l_{fund}}{b_{fund}} - \left(n_{obj_1} \cdot \frac{l_{obj_1}}{b_{obj_1}} + n_{obj_2} \cdot \frac{l_{obj_2}}{b_{obj_2}} \right)$$

$$\Delta h_{comp} = n_{fund} \cdot \frac{l_{fund}}{\sqrt{n_{fund}}} - \left(n_{obj_1} \cdot \frac{l_{obj_1}}{\sqrt{n_{obj_1}}} + n_{obj_2} \cdot \frac{l_{obj_2}}{\sqrt{n_{obj_2}}} \right)$$

Em que l é o perímetro do objeto e b é perímetro do retângulo envolvente do objeto.

Assim, a *heterogeneidade de suavidade* é igual à razão entre o comprimento de borda l do objeto e o comprimento da borda b dado pelo retângulo envolvente do objeto paralelo as bordas da imagem.

A heterogeneidade de compacidade é igual à razão entre o comprimento da borda l e a raiz quadrada do número de pixel que é formado esse objeto de imagem.

O parâmetro de escala é o critério de parada do processo de otimização, ou seja, dois objetos adjacentes serão fusionados se o critério de heterogeneidade f calculado não exceda o parâmetro de escala determinado.

Além da especificidade em relação à construção do critério de similaridade, esse algoritmo tem como uma importante característica a possibilidade de segmentar uma mesma imagem em níveis de escala diferenciados que se relacionam entre si, formando uma rede hierárquica de objetos (BAATZ; SCHÄPE, 2000). Desta forma, cria-se a concepção de super-objetos e sub-objetos. Os primeiros são os objetos localizados em um nível superior, que agregam objetos de um nível inferior. Na rede hierárquica formada, cada objeto “sabe” a que super-objeto pertence no nível superior, “reconhece” seus sub-objetos no nível inferior e “conhece” seus vizinhos no nível hierárquico onde está contido (BENZ et al., 2004). Esse tipo de informação topológica pode ser utilizada na classificação dos objetos e constitui-se em uma das maiores vantagens apresentadas pela análise de imagens orientada a objeto. A Figura 9 mostra essa hierarquia. A hierarquia dos objetos permite a representação da informação da imagem em diferentes escalas simultaneamente.

estratégias implementadas: regra do vizinho mais próximo; classificação baseada em regras utilizando lógicas booleana e *fuzzy*. Em ambos os casos, não é analisado o pixel e sim os objetos formados e isso tem a vantagem de diminuir a relação sinal/ruído nos objetos, diminuir os requisitos computacionais e adicionar aos objetos características significativas não disponíveis em análise por pixel como geometria, relações com a vizinhança no mesmo nível e em diferentes níveis (BENZ et al., 2001). O fato de se trabalhar com objetos não produzirá, na classificação, o efeito “*salt and pepper*” que ocorre na classificação por pixel, onde alguns *pixels* são classificados diferentemente da área ao seu redor impedindo a formação de áreas homogêneas. Esse efeito seria mais notado ainda em imagens SAR, devido à presença o *speckle* que produz uma heterogeneidade maior na imagem.

O classificador *Nearest Neighbor* é mais recomendado para uma classificação simples e rápida dos objetos baseados numa amostra de objeto. Depois que uma série de amostras é definida como pertencendo a uma classe, cada objeto é designada para a classe cujas características são mais próxima à referida classe no hiper espaço de atributos.

A classificação baseada em regras, que foi adotada nesta pesquisa, faz a descrição de cada classe associando um conjunto de regras booleanas e/ou *fuzzy* que são utilizados para atribuir um objeto a uma determinada classe. Esse conjunto de regras não é limitado apenas ao comportamento espectral do alvo, mas também a atributos relacionados às características espaciais e de contexto.

Neste programa é possível a entrada de várias datas para a segmentação e também elaborar regras de decisão baseada nessas várias entradas. Isso permite uma análise orientada a objeto de dados multitemporais, o que é importante para aplicações em que uma única dada de imageamento é insuficiente como, por exemplo, o mapeamento de cobertura da terra, monitoramento de desmatamento e inventários agrícolas.

Nesse sentido, alguns estudos tem mostrado a importância da utilização de dados multitemporais para a melhoria na precisão de classificação de imagens. Em Del Frate et al. (2003) a acurácia da classificação baseada em quatro aquisições SAR aumentou em 30% quando comparada com os resultados de uma única aquisição. Blaes et al. (2005) compararam o desempenho de vários conjuntos de dados multitemporais ERS e a acurácia da classificação aumentou significativamente com o aumento da quantidade de imagens. Skriver (2008) utilizando-se de um conjunto de dados SAR, incluindo polarização simples, polarização dual e dados polarimétricos, comparou a acurácia da classificação de cobertura da terra em área agrícola fazendo uso apenas das polarizações e acrescentando aquisições multitemporais. O

resultado alcançado por esse autor demonstrou que a classificação melhora significante quando é acrescentada a componente temporal.

Desta maneira a análise temporal juntamente com a abordagem baseada na orientação a objeto para a análise e classificação de imagens SAR vem se tornando um campo interessante a ser explorado.

3. AVALIAÇÃO DE CLASSIFICAÇÃO

A verificação da qualidade de um mapa temático normalmente é feita através da análise da acurácia temática, que está relacionada à acurácia das classes temáticas presente no mapa em relação às correspondentes na realidade (CONGALTON; GREEN, 2008). A acurácia é baseada em coeficientes estatísticos e tem como objetivo produzir uma matriz de confusão de onde se extraem esses coeficientes, os quais indicam a acurácia das classes individuais e do mapa como um todo.

A matriz de erro compara a informação dos dados de referência com a informação do mapa através de elementos amostrais. Essa matriz é uma matriz quadrada, ou seja, com número igual de colunas e linhas (Tabela 1). As colunas representam os dados de referência, enquanto as linhas indicam os elementos da classificação gerados a partir dos dados de sensoriamento remoto (CONGALTON E GREEN, 2008).

Tabela 1: Exemplo de matriz de confusão

		Dados de referência				
		Classe 1	Classe 2	Classe 3	Classe 4	Total
Dados classificados	Classe 1	65	4	22	24	115
	Classe 2	6	81	5	8	100
	Classe 3	0	11	85	19	115
	Classe 4	4	7	3	90	104
	Total	75	103	115	141	434

Os valores da diagonal principal da matriz representam os elementos que foram classificados corretamente, e a razão entre a soma destes elementos pelo número total de elementos da matriz resulta na exatidão global da classificação. A partir da matriz de confusão também pode ser calculada a exatidão para as classes individuais. A exatidão global é estimada a partir da expressão a seguir:

$$exatidão\ global = \frac{\sum_{i=1}^k x_{ii}}{N}$$

Em que x_{ii} são os elementos da diagonal principal, k o número de classes e N o número total de amostras.

A acurácia pode ser analisada individualmente por meio da análise dos erros de inclusão (erros de comissão) e erros de exclusão (erros de omissão) presentes na classificação. Um erro de comissão ocorre ao incluir um objeto na classe a qual ele não pertence e o de omissão quando um objeto é excluído da classe a que pertence. Na matriz de erro esses valores são obtidos por meio das acurácia do usuário e do produtor, respectivamente (STORY; CONGALTON, 1986).

A exatidão do usuário (*user's accuracy*) é expressa pela razão do número de elementos distribuídos corretamente em uma classe pelo número total de elementos classificados na mesma. A exatidão do produtor (*producer's accuracy*) é a razão entre o número de elementos classificados corretamente em uma determinada classe pelo número de elementos de referência amostrados para a mesma classe (CONGALTON E GREEN, 2008). Essas medidas são representadas matematicamente pelas seguintes expressões:

$$exatidão\ do\ usuário = \frac{n_{ii}}{n_{i+}}$$

Em que n_{ii} é o número de elementos classificados corretamente da classe i ; n_{i+} é o total de elementos classificados para a classe i ; e

$$exatidão\ do\ produtor = \frac{n_{ii}}{n_{+i}}$$

Em que n_{ii} é o número de elementos classificados corretamente da classe i ; n_{+i} é o total de elementos de referência para a classe i .

Exemplificando essas expressões na matriz de erro da Tabela 2, tem-se:

Tabela 2: Matriz de confusão com a exatidão global.

		Dados de referência					
		Classe 1	Classe 2	Classe 3	Classe 4	Total	Acurácia do usuário
Dados classificados	Classe 1	65	4	22	24	115	65/115 = 57%
	Classe 2	6	81	5	8	100	81/100 = 81%
	Classe 3	0	11	85	19	115	85/115 = 74%
	Classe 4	4	7	3	90	104	90/104 = 87%
	Total	75	103	115	141	434	
Acurácia produtor		65/75= 87%	81/103= 79%	85/115= 74%	90/141= 64%		65+81+85+90/434 =74%

$$exatidão\ global = \frac{65 + 81 + 85 + 90}{434} = 0,74 = 74\%$$

A partir da matriz de erro pode-se calcular o coeficiente de concordância *Kappa* que é baseado na diferença entre concordância observada (a concordância entre a classificação e os dados de referência dado pela diagonal principal da matriz) e a chance de concordância entre os dados de referência e uma classificação aleatória, ou seja, produto entre os totais marginais da matriz (CONGALTON E GREEN, 2008). O coeficiente *Kappa* é dado pela seguinte expressão:

$$\hat{k} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}}$$

Em que k é o número de classes; n_{ii} é o número de elementos classificados corretamente; n_{i+} é o total de elementos classificados para uma classe i ; n_{+i} é o total de elementos de referência para uma classe i ; n é o número total de elementos amostrais ou tamanho da amostra.

4. PLATAFORMA ALOS

O sistema ALOS (*Advanced Land Observing Satellite*) representa o maior satélite japonês de observação da terra e foi lançado em 24 de janeiro de 2006, pela Agência de Exploração Aeroespacial Japonesa (*Japan Aerospace Exploration Agency*- JAXA). O sistema carrega dois instrumentos ópticos (PRISM – *Panchromatic Remote-sensing Instrument for Stereo Mapping* e AVNIR-2 – *Advanced Visible and Near-Infrared Radiometer type 2*) e um radar de abertura sintética (PALSAR – *Phased Array L-band Synthetic Aperture Radar*).

A plataforma ALOS descreve uma órbita polar heliosíncrona a aproximadamente 692 km de altitude, passando pela linha do Equador às 10:30h e 22:30h, em suas órbitas descendente e ascendente respectivamente. Com um ciclo de 46 dias, o satélite requer 671 órbitas para completar um ciclo. Contudo, a plataforma dispõe de uma complexa configuração de passagem que possibilita a revisita em dois dias no caso dos instrumentos de visada lateral.

4.1.PALSAR (*Phased Array L-band Synthetic Aperture Radar*)

O PALSAR é um radar imageador de abertura sintética que está presente no sistema ALOS. É considerado o sucessor do JERS (*Japanese Earth Resources Satellite*), que esteve em operação de 1992 a 1998, mas apresenta melhorias significativas não apenas no desempenho radiométrico e geométrico, mas também nas características do sensor, principalmente no que diz respeito à polarimetria (completa no PALSAR), às possibilidades de variação nas visadas off-nadir e às operações no modo ScanSAR. O PALSAR possui as quatro polarizações (HH, VV, HV e VH), opera na banda L, numa frequência de 1270 MHz (23,6 cm) e pode ser operado em diferentes modos: FBS (*Fine Beam Single polarization*), FBD (*Fine Beam Dual polarization*), POL (modo polarimétrico) e ScanSAR. (ROSENQVIST et al. 2007)

As imagens podem ser processadas com diferentes níveis sendo que . As imagens do sensor PALSAR possuem os seguintes níveis de processamento: 1.0; 1.1 e 1.5. A diferença básica entre estes níveis de processamento é que no nível 1.0 o sinal é bruto, sem processamento; o nível 1.1 o dado é complexo com uma visada (*single-look complex*) e o nível 1.5 o dado é em amplitude e múltiplas visadas (*mult-look*).

A Tabela 3 apresenta algumas características desse sensor.

Tabela 3: Características do sensor PALSAR/ALOS.

Frequência	1.270 MHz (Banda L)			
Modo	Fino (Fine)		ScanSAR	Polarimétrico
Chirp Bandwidth	28 MHz	14 MHz	28 MHz e 14 MHz	14 MHz
Polarização	HH	HH + HV	HH	HH+HV+VH+VV
Ângulo de incidência	8° ~ 60°	8° ~ 60°	18° ~ 43°	8° ~ 60°
Resolução em alcance (range)	7 ~ 44m	14 ~ 88m	100m (<i>multilook</i>)	24 ~ 89m
Largura de faixa	40 ~ 70 km	40 ~ 70 km	250 ~ 350 km	20 ~ 65 km

Fonte: JAXA, 2007

4.2. PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*)

O PRISM é um sensor óptico cujas imagens adquiridas são pancromáticas (comprimentos de ondas entre 0,52 e 0,77µm), apresentando resolução espacial de 2,5 m no nadir, o que fornece modelo digital de superfície (*Digital Surface Model- DSM*) com boa acurácia, e resolução radiométrica de 8 bits. O PRISM é composto por 3 sistemas ópticos independentes, um com visada Nadir e dois com visadas inclinadas para frente (*Forward*) e para trás (*Backward*), tornando possível o imageamento estereoscópico na mesma órbita, ao longo da trajetória do satélite. (JAXA, 2007) A Tabela 4 mostra algumas características desse sensor.

Tabela 4: Características do sensor PRISM.

No. de Bandas	1 (Pancromática)
Comprimento de Onda	0,52 ~ 0,77 microns
No. de Sensores	3 (nadir/para frente/para trás)
Relação Base/Altura (B/H)	1,0 (entre as visadas para frente e para trás)
Resolução Espacial	2,5 m
Largura de faixa	35 km (modo triplet) 70 km (apenas nadir)
No. de Detectores	28.000/banda (faixa de 70 km) 14.000/banda (faixa de 35 km)
Inclinação da Visada	de -1,5 a +1,5 graus (transversal à trajetória no modo Triplet)
Resolução Radiométrica	8 bits

Fonte: JAXA, 2007

5. ÁREA DE ESTUDO

A área de estudo está localizada em um trecho do reservatório de Barra Bonita, no estado de São Paulo, entre as coordenadas $22^{\circ}24'12''\text{S}$, $48^{\circ}15'26''\text{W}$ e $22^{\circ}46'29''\text{S}$, $47^{\circ}48'13''\text{W}$ abrangendo parte dos municípios de Anhembi, Santa Maria da Serra, São Pedro e Torrinha (Figura 10).



Figura 10: Localização da área de estudo.

O reservatório de Barra Bonita é resultado do represamento dos rios Tietê e Piracicaba entre os municípios de Barra Bonita e Igarapu, além de inúmeros tributários que drenam suas águas para esses dois rios de maior importância (CALIJURI, 1988). É o primeiro de uma série de reservatórios construído ao longo do rio Tietê e entrou em funcionamento a partir de 1963. Além de ser um importante recurso hídrico-energético, o reservatório também exerce outros fins como transporte fluvial, irrigação, recreação e abastecimento de água. Por estar localizado numa região bastante desenvolvida e populosa do interior do estado de São Paulo o reservatório atua como corpo receptor de despejos domésticos e industriais, principalmente do beneficiamento da cana de açúcar. A monocultura intensiva de cana de

açúcar é a principal atividade agrícola desenvolvida na região, o qual é principalmente utilizada para produção de etanol como combustível automobilístico e para produção de açúcar. Na safra de 2008/2009 o estado de São Paulo foi responsável pela produção de 60,8% da produção total de cana de açúcar do Brasil e 68,6% da produção da região Centro-Sul (UNICA, 2010). Na região são encontrados plantações de citricas e atividades de silvicultura, porém em menor quantidade. Em vários pontos do reservatório ocorre a extração de areia para a construção civil e argila. Essa extração é feita por meio de dragagem do leito do rio e bombeamento do material para tanques colocados nas margens (ESPINDOLA, 1994).

A área de estudo está localizada na extensão espacial que corresponde à transição entre a Depressão Periférica Paulista (zona do médio Tietê) e as Cuestas Basálticas, tendo como nível de base regional o Rio Piracicaba. O desnível na região da Cuesta pode atingir até 1000 m na Serra de São Pedro.

A região está inserida em uma área de transição entre os climas tropical e subtropical, não apresentando estações climáticas bem definidas, sendo mais nítido o período chuvoso (verão) e o período seco (inverno) (CALIJURI, 1998). A Figura 11 mostra a precipitação entre janeiro de 2008 e fevereiro de 2009 obtidas no posto meteorológico da Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo (ESALQ/USP). Os meses de aquisição dos dados estão indicados no gráfico por setas vermelhas e pode-se observar que março de 2008 e janeiro de 2009 foram meses com precipitação média de 4,3mm e 5,3mm, diferente de julho de 2008 em que não houve precipitação, portanto o mês mais seco da análise. Esse dado é importante para a interpretação dos dados, uma vez que a umidade interfere no retroespalhamento dos alvos.




Figura 11: Precipitação na região de estudo durante o período próximo aos meses de aquisição dos dados PALSAR.

6. MATERIAL UTILIZADO E PROCEDIMENTOS METODOLÓGICOS

6.1. Material utilizado

Para o desenvolvimento dessa pesquisa foram utilizados os seguintes dados e programas, além do equipamento Topcon Hiper GPS.

6.1.1. Dados

- a) Três imagens ALOS/PALSAR adquiridas em três datas diferentes. A descrição destas imagens está na Tabela 5.

Tabela 5 : Descrição das imagens PALSAR utilizados na pesquisa

	Imagem 1	Imagem 2	Imagem 3
Data de aquisição	08/04/2008	09/07/2008	09/01/2009
Modo	FBS	FBD	FBS
Looks	2	4	2
Polarizações	HH	HH e HV	HH
Tamanho pixel	6,25m	12,5m	6,25m
Nível de processamento	1.5	1.5	1.5

- b) Uma imagem ALOS/PRISM ortoretificada nadir adquirida no dia 21/04/2007.
- c) Um DSM PRISM com resolução altimétrica de 1m e resolução espacial de 2,5m reamostrado para 12,5m adquirido no dia 21/04/2007.
- d) Dados de campo obtidos em duas campanhas nos períodos de 23 e 24 de abril de 2009 e 23 a 25 de setembro de 2010.

Todos os dados estão referenciados ao sistema de projeção UTM, zona 23S e utilizando o *Datum* WGS84.

As imagens foram cordialmente cedidas pela JAXA por intermédio da PhD. Laura Hess.

6.1.2. Programas

- a) PCI 10.1.3: utilizado para a ortoretificação das imagens.
- b) Envi 4.6: utilizado para edição das imagens
- c) eCognition 8.0: utilizado para a análise orientada a objetos
- d) ArcGis 9.2: utilizado para o pós-processamento.
- e) MINITAB 14: utilizado para análises estatísticas.

6.2. Procedimentos metodológicos

Para atingir o objetivo desta pesquisa foram executados alguns procedimentos que são apresentados no fluxograma da Figura 12 e descritos em seguida.




Figura 12: Fluxograma do procedimento metodológico.

6.2.1. Correções do terreno

O processo de correção do terreno das imagens PALSAR foi necessário para minimizar as distorções geométricas provocadas pelo sistema de imageamento do sensor e para que as imagens PALSAR nas diferentes datas fossem co-registradas de maneira mais precisa. Para a realização dessa etapa foi utilizado o DSM produzido a partir das estereoscópicas PRISM e da imagem PRISM nadir ortorectificada para o mesmo quadro do DSM o qual foi gerado pela JAXA utilizando o programa *DSM and Ortho Image Generation ALOS PRISM* (DOGS-AP).

A correção das imagens foi feita pelo modelo de *Toutin* do módulo *OrthoEngine* do programa PCI Geomatica V.10.1.3 o qual é utilizado para ortorectificação de imagens ALOS. Esse é um modelo rigoroso que calcula a posição e a orientação do sensor quando a imagem foi capturada e usa pontos de controle, combinados com o conhecimento da geometria rigorosa do sensor, para calcular o melhor ajuste das imagens na projeção.

Antes de realizar esse processamento nas imagens PALSAR foi feito um trabalho de campo para verificar a acurácia planimétrica e altimétrica da imagem PRISM ortorectificada e do DSM gerados pela JAXA uma vez que esse processamento foi realizado sem pontos de controle. Para a realização dessa tarefa foram coletados 16 pontos de controle utilizando o Topcon Hiper GPS no modo estático, cuja precisão nominal horizontal é de 3mm e a vertical de 5mm. Esses pontos foram bem distribuídos na imagem e coletados em pontos facilmente identificados na imagem PRISM como, por exemplo, quinas do telhado de casas. A Figura 13 mostra a aquisição de dois pontos.



Figura 13: Pontos de coleta de dados planimétricos e altimétricos

O tempo de coleta de dados em cada ponto foi de 30 minutos para eliminar a ambigüidade, uma vez que não foi utilizada estação base. Os dados foram processados na FCT/UNESP campus de Presidente Prudente e a análise da acurácia planimétrica (E e N) e altimétrica (z) foi calculada através do RMSE (*Root Mean Square Error*) que é dado pela expressão a seguir.

$$RMSE = \sqrt{\frac{\sum (x_o - x_{GPS})^2}{n}}$$

Sendo,

x_o : coordenada observada;

x_{GPS} : coordenada verdadeira obtida pelo GPS.

n : número total de pontos avaliados.

Verificada a acurácia planimétrica e altimétrica da imagem PRISM ortoretificada gerada pela JAXA, foi realizado a correção do terreno nas imagens PALSAR. Os pontos de controle (GCP- *Ground Control Points*) para esse processo foram adquiridos a partir da imagem PRISM ortoretificada. O total de pontos obtidos foi 12, dispostos de modo que estivessem o mais distribuídos possível na imagem. A partir disso, o processamento foi realizado para as três datas de aquisições das imagens PALSAR. Nesse processo também foi realizado a reamostragem das imagens 1 e 3 modificando o tamanho do pixel de 6,25m para 12,5m. Desta maneira todas as cenas ficaram com os *pixels* na mesma dimensão, 12,5m.

Após a correção e o co-registro das imagens PALSAR foi possível utilizar as informações de mudanças dos alvos entre os períodos de aquisição das imagens, uma vez que a sobreposição delas pode ser feita de maneira correta.

6.2.2. Definição das classes

Antes de passar para a etapa de segmentação foram definidas quais classes seriam mapeadas na imagem, para só então definir os parâmetros da segmentação, pois estes dependem do objetivo a ser atingido.

Desta maneira a escolha das classes foi baseada no conhecimento prévio da área adquiridos com visitas a campo e no sistema de classificação proposto pela *Food and Agriculture Organization* (FAO) das Nações Unidas e o *United Nations Environment*

Programme (UNEP), denominado *Land Cover Classification System (LCCS)* na segunda versão publicado em 2005. Esse projeto foi desenvolvido para satisfazer a necessidade de melhorar o acesso a informações confiáveis e padronizadas sobre a cobertura vegetal e mudanças da terra. É um sistema de classificação a priori, abrangente e padronizado concebido para satisfazer necessidades específicas dos usuários, independente da escala ou dos meios utilizados para o mapeamento. O *LCCS* também reforça o processo de normalização e minimiza o problema de se lidar com uma grande quantidade de classes pré-definidas.

6.2.3. Segmentação

Nesta etapa foram realizados vários testes dos parâmetros de escala, forma e compacidade para a segmentação das imagens PALSAR utilizando o algoritmo de crescimento de regiões complementado no programa *eCognition* (BAATZ; SCHÄPE, 2000) de modo que os objetos formados fossem representativos dos alvos e respeitassem ao máximo as bordas dos alvos.

Cada polarização das imagens PALSAR foi considerada como um plano de informação de entrada no programa e denominadas segundo o mês e ano de aquisição da imagem como mostra a Tabela 6. A imagem PRISM não foi segmentada e nem classificada, sendo apenas utilizada no processo de avaliação da classificação. Portanto os planos de informação utilizados no *eCognition* foram apenas das imagens PALSAR. Todas os planos de informação foram consideradas no processo de segmentação com o peso igual a 1.

Tabela 6: Denominação das polarizações

Imagem	Polarização	Plano de informação
Imagem 1	HH	HH_abr08
Imagem 2	HH	HH_jul08
	HV	HV_jul08
Imagem 3	HH	HH_jan09

6.2.4. Classificação

O processo de classificação foi dividido em três fases. A primeira fase consistiu na caracterização das classes, ou seja, encontrar as principais características baseada nos processos de interação do alvo com a microonda e as relações espaciais entre os objetos das classes. Na segunda fase foi feito o mapeamento das classes de maneira geral. As regras dessa fase foram elaboradas basicamente em função das características do retroespalhamento dos alvos nas polarizações disponíveis a partir de amostras de treinamento adquiridas em observações de campo. Na terceira foi feito o refinamento do mapeamento realizado na segunda etapa utilizando regras de relação espacial com as classes vizinhas, seja relação de bordas quanto de área e distância, além de regras relacionadas a forma dos alvos.

Após a caracterização das classes a classificação na fase dois foi dividida em 3 etapas:

- etapa 1: nessa etapa foi criada uma classe abstrata denominada “brilhante” em que todos os objetos com retroespalhamento muito alto em todas as cenas na polarização HH foram alocados. Em seguida foram aplicadas novas regras de modo que esses objetos fossem designados as suas reais classes.
- etapa 2: nessa etapa foi criada outra classe abstrata chamada “escura” a qual foram associados os objetos com retroespalhamento baixo em todas as polarizações. Então esses objetos foram alocados em suas respectivas classes.
- etapa 3: nessa etapa os demais objetos, ou seja, aqueles com retroespalhamento intermediário foram mapeados.

6.2.5. Avaliação da classificação

Concluído o processo de classificação foi feita a avaliação do resultado final. Para isso foi verificada a acurácia temática da classificação com base na matriz de erro. A partir dela foi feita a análise do coeficiente *Kappa*, a acurácia global, do produtor e do usuário.

Para avaliar a classificação é necessário utilizar dados de referência, dados como verdade, para serem comparados com o resultado final. Desta maneira os dados utilizados como verdade foram baseados em conhecimento adquirido em visitas a área de estudo, interpretação da imagem PRISM cuja resolução é de 2,5m e pela inspeção visual de imagens de alta resolução na web (^{©2006}Google EarthTM).

Os pontos de verificação foram adquiridos com a aplicação da técnica de amostragem aleatória estratificada. Congalton (1988b) sugere que o numero de amostras para uma área de estudo menor que um milhão de hectares e com menos de 12 classes seja 50 amostras por classes. Desta maneira, foi gerada uma grade de 14x8 da área de estudo e sorteado de maneira aleatória 5 pontos dentro de cada célula formada totalizando 560 pontos de amostragem. Esse processo foi feito utilizando o programa Erdas ImagineTM (version 9.3). A Figura 14 apresenta a grade e o conjunto de pontos para a amostragem.




Figura 14: Conjunto de pontos utilizados para a avaliação da classificação.

7. RESULTADOS E DISCUSSÕES

Os resultados gerados após a aplicação dos procedimentos metodológicos são apresentados e discutidos a seguir.

7.1. Correções do terreno

A acurácia planimétrica e altimétrica da imagem PRISM ortoretificada e do DSM é apresentada na Tabela 7.

Tabela 7: Acurácia planimétrica e altimétrica.

Acurácia Planimétrica- PRISM-Orto	
RMSE (E)	5,7 m
RMSE (N)	8,4 m
RMSE (TOTAL)	10,2 m
Acurácia Altimétrica- DSM	
RMSE (z)	5,2 m

Como o produto final dessa pesquisa é um mapa temático de cobertura da terra não é necessário que a acurácia planimétrica e altimétrica seja grande, basta que esteja compatível com a dimensão do elemento de resolução das imagens ALOS PALSAR – 12,5m, portanto foram considerados bons para a realização da ortoretificação das imagens PALSAR.

O DSM utilizado e o resultado da correção do terreno são apresentados na Figura 15.




Figura 15: a) DSM utilizado para a correção do terreno; b) composição colorida da imagem PALSAR.

7.2. Definição das classes

A hierarquia das classes baseada no sistema de classificação proposto por LCCS (2004) está mostrada na Figura 16 e em vermelho estão as classes que foram mapeadas.









Figura 16: Hierarquia das classes mapeadas.

7.3. Segmentação

Os resultados mais relevantes dos testes dos parâmetros escala, compacidade e forma do algoritmo *multiresolution segmentation* são apresentados na Tabela 3.

Tabela 8: Testes dos parâmetros de segmentação.


Imagem	Teste 1 Escala ; forma ; compacidade 80 ; 0,1 ; 0,1
	
Teste 2 Escala ; forma ; compacidade 80 ; 0,1 ; 0,5	Teste 3 Escala ; forma ; compacidade 80 ; 0,1 ; 0,9
	
Teste 4 Escala ; forma ; compacidade 80 ; 0,5 ; 0,9	Teste 5 Escala ; forma ; compacidade 80 ; 0,9 ; 0,9
	

Através da comparação das segmentações realizadas com diferentes pesos para compacidade e mantendo-se fixo os parâmetros de escala e peso da forma, observou-se que o resultado com o peso de 0,9 gerou resultado mais satisfatório. Quando foi utilizado o menor peso (0,1) houve uma segmentação maior com a formação de objetos desnecessários. Quando se utilizou o peso 0,5 que é um valor intermediário, já que a variação é de 0,1 a 0,9, houve uma certa confusão entre os objetos como mostra o teste 2 da Tabela 8 em que em um objeto

há a presença de cítricas e mata. Utilizando o maior peso para a compacidade (0,9) não houve essa confusão e nem a supersegmentação gerada com o peso 0,1. Isso se deve pelo fato de que quando é designado um peso alto para a compacidade, o algoritmo faz o crescimento das regiões buscando gerar objetos mais compactos. Apesar da compacidade ser um atributo importante na avaliação da forma, no cômputo geral não foi atribuído um peso elevado para a forma. A forma não foi considerada com peso alto porque é mais importante ser considerada a resposta do retroespalhamento na imagem SAR, que no algoritmo é dado como “cor” do que a forma dos objetos.

A escala foi testada com os valores de 10, 30, 60, 80, 120 e 150. Os três primeiros valores geraram uma supersegmentação dos objetos e o último provocou a fusão de objetos de diferentes classes. Assim sendo, o valor de 80 foi adotado para a segmentação. A Tabela 9 apresenta os valores de parâmetros adotados.

Tabela 9: Parâmetros para a criação dos níveis de segmentação.

Imagem não segmentada	Nível 1		
	Escala: 80	Forma: 0,1	Comp:0,9
			

7.4. Classificação

7.4.1. Caracterização das classes

7.4.1.1. Cana de açúcar

A cana de açúcar é considerada um tipo de cultura anual, ou seja, ela é plantada, se desenvolve e é colhida entre 12 e 18 meses dependendo da variedade. A Figura 17 mostra como normalmente é o ciclo da cana de açúcar durante o ano.




Figura 17: Ciclo da cana de açúcar.

A cana chamada de ano e meio, cujo ciclo de vida é em torno de 18 meses, é a que tem melhor qualidade e seu plantio normalmente se realiza entre janeiro e março. Sua maturação ocorre em torno de junho e julho do ano seguinte que é quando começa sua colheita. A cana de ano tem um ciclo menor que a anterior, em torno de 12 meses. Seu plantio geralmente ocorre entre setembro e dezembro e sua colheita começa por volta de setembro do ano seguinte. Porém, como os produtores querem manter sempre a terra produzindo pode haver alternância entre um tipo e outro de cana de açúcar na propriedade, como também algumas alterações dos períodos de plantio e colheita.

A estrutura da cana de açúcar é de hastes finas e folhas alongadas podendo atingir a altura de 3m antes da colheita. A Figura 18 ilustra a cana de açúcar encontrada na área de estudo.



Figura 18: Exemplos de cana de açúcar encontrada na área de estudo.

Essa variação da cana de açúcar em um intervalo de tempo relativamente pequeno é refletido no retroespalhamento desse alvo em uma análise temporal com uma frequência alta, capaz de capturar alterações num único período sazonal, como é o caso dessa pesquisa. Quando a cana de açúcar acabou de ser plantada até que atinja uma altura maior que o comprimento de onda do sinal da banda L (23.6 cm) seu retroespalhamento tanto na polarização HH quanto na HV é baixo, sendo praticamente a resposta da terra. Com o desenvolvimento da cultura até a maturação o retroespalhamento também aumenta, uma vez que a estrutura que interage com o sinal é maior. A Figura 19 mostra uma região de cana de açúcar com dois diferentes estágios de cultura. Na área **A** há presença de cana de açúcar em abril e em julho, mas em janeiro de 2009 já houve o corte. Isso pode ser notado pelos tons de cinza mais claro em abril e julho e tons mais escuros em janeiro na polarização HH, o que significa que o retroespalhamento em abril e julho é maior do que em janeiro, ou seja, havia cultivo nos dois primeiros meses da análise e não mais no ultimo. Já na área B os tons de cinza são mais claros apenas em abril. Em julho e janeiro apresentou tons escuros. Isso implica dizer que o retroespalhamento foi mais alto apenas em abril quando havia a presença de cana de açúcar.




Figura 19: Plantação de cana de açúcar em diferentes estágios.

7.4.1.2. Reservatório, rios e lagos

Essa classe tem como característica principal a ocorrência do espalhamento especular, ou seja, o sinal emitido pelo radar atinge a superfície de água e é retroespalhado para a região fora do alcance do sensor. Sendo assim, o valor do retroespalhamento tanto da polarização HH quanto na HV é baixo e na imagem isso é representado com tons de cinza escuro e na composição colorida com cor próxima ao preto. Outra característica dessa classe é que sua resposta praticamente não se altera ao longo do tempo.

A Figura 20 mostra uma composição colorida da região da área de estudo que é cortada pelo rio Piracicaba.




Figura 20: Exemplo de reservatório, rios e lagos.

A região meândrica do curso d'água onde o canal é estreito o atributo de forma chamado densidade (*Density*) ajuda no mapeamento dessa classe, pois descreve a distribuição

dos *pixels* do objeto. No eCognition significa que objetos densos tem a forma mais quadrada e na imagem tem a tonalidade mais clara. Objetos compridos e finos, como o canal do rio, têm valor de densidade baixa apresentando tonalidade escura na imagem (Figura 21).




Figura 21: Atributo de forma geométrica densidade (*density*).

7.4.1.3. Gramínea

Essa classe é caracterizada por pequena estatura, geralmente menor que 30 cm de altura (Figura 22). Desta maneira a interação do sinal de radar na banda L, cujo comprimento de onda é de 23.6 cm, com a gramínea é bem pequena fazendo com que o retroespalhamento seja baixo. Na imagem SAR isso é representado por tons de cinza escuro. Na análise temporal de alta frequência a gramínea pouco se altera com o tempo, fazendo com que sua resposta seja sempre muito parecida. Um dos fatores que pode provocar alterações no retroespalhamento desse alvo é a umidade da terra, pois se este encontra-se com maior teor de umidade, aumentará o retroespalhamento do alvo como já explicado anteriormente. A Figura 23 mostra a uma região de gramínea na área de estudo em composição colorida e as polarizações HH. Pode-se observar que em julho a tonalidade de cinza é a mais escura e o valor médio do retroespalhamento nessa área é o mais baixo.



Figura 22: Região de gramínea dentro da área de estudo





Figura 23: Regiões de gramínea na área de estudo.

Outro fator que pode fazer variar o retroespalhamento desse alvo é a orientação da vertente em que esse alvo se encontra. Se a vertente onde a gramínea está localizada estiver voltada para a linha de imageamento do sensor, ou seja se essa superfície receber o sinal com ângulo de inclinação mais próximo da normal, o retroespalhamento será um pouco maior do que na vertente oposta como mostrado na composição colorida da Figura 24 em que A é a vertente voltada para o imageamento e apresenta tonalidade mais clara que em B que é a vertente oposta.




Figura 24: Região de gramínea na vertente voltada para o imageamento(A) e na vertente oposta (B).

7.4.1.4. Mata natural

A mata natural arbórea presente na área é representada pela Floresta Estacional Semidecidual e por uma região de capoeira onde ocorre a regeneração da vegetação (NASCIMENTO e GARCIA, 2004). Essa classe apresenta uma estrutura com grande número de galhos e copa volumosa com altura média de 10 m. A Figura 25 mostra a mata natural em zonas ripárias, na encosta da cuesta e em propriedades rurais.




Figura 25: a) mata natural em propriedade; b) mata natural em zona ripária; c) mata natural na cuesta

A estrutura da mata natural configura esse alvo como sendo um volume difuso onde ocorre o espalhamento volumétrico em que a onda é espalhada múltiplas vezes. A polarização HV é onde esse espalhamento é mais evidente e é identificada com tons de cinza bastante claro. A estrutura desse tipo de cobertura não se altera muito no curto período de tempo envolvido neste trabalho. O que implica dizer que o retroespalhamento dessas regiões não tem grandes variações. Em algumas áreas as árvores encontram-se mais esparsas, não apresentando um grande volume de galhos refletindo um retroespalhamento mais baixo em relação a área densa. A Figura 26 apresenta uma região de mata natural nas polarizações HH e HV.




Figura 26: Retroespalhamento em mata natural nas polarizações HH e HV.

7.4.1.5. Vegetação úmida

A vegetação de área úmida presente na região de estudo é formada, em sua grande maioria, por vegetação herbácea (Figura 27). Segundo estudos realizados por Martins et al (2008) durante o período de fevereiro a setembro de 2002 identificaram a presença de mais significativa das espécies emersas *B. arrecta*, *B. mutica*, *E. crassipes* e *Typha angustifolia* no reservatório de Barra Bonita e Carvalho et al (2003) destacaram as espécies *B. arrecta*, *B. mutica* e *E. crassipes* como as mais importantes em levantamento realizado nos meses de junho e julho de 2001.



Figura 27: Vegetação em área úmida na região de estudo.

Uma parte dessa vegetação fica mais evidente em períodos de águas altas como é observado no retroespalhamento do sinal em janeiro como mostrado na Figura 28. Outra parte é identificada em todos os períodos da análise apresentando um retroespalhamento alto em todos os meses como apontado na Figura 28. Com isso é possível mapear essa região utilizando a variação temporal adotada nessa pesquisa.




Figura 28: Retroespalhamento da vegetação úmida nas polarizações HH

7.4.1.6. Eucaliptos

A plantação de eucaliptos é a classe que apresenta as árvores mais altas encontradas nesse estudo variando entre 15m e 20m de altura. A estrutura de seus troncos e galhos faz dessas áreas um volume difuso (Figura 29).



Figura 29: Plantação de eucalipto presente na área de estudo.

Porém, o alinhamento e o espaçamento constante (aproximadamente 3m x 3m) dessas plantações fazem com que o o volume das copas e galhos não seja tão grande quanto o encontrado em matas naturais. Com isso o espalhamento volumétrico não é tão intenso quanto o que ocorre na mata natural. Isso pode ser visto na polarização HV em uma área em que há uma plantação de eucaliptos ao lado de uma mata natural como mostra na Figura 30.




Figura 30: Diferença entre eucalipto e mata.

O ciclo de vida do eucalipto varia de 5 a 10 anos dependendo da finalidade da plantação, portanto não ocorrem grandes variações em uma análise temporal dentro de um único período sazonal a não ser que seja a época de corte. A Figura 31 mostra três situações do eucalipto. Há uma área em que o eucalipto foi cortado dentre julho de 2008 e janeiro de 2009 (Figura 31A). Outra área que o eucalipto estava sendo cortado em janeiro (Figura 31B) e outra em que o eucalipto não foi cortado (Figura 31C). Isso é caracterizado pela variação do retroespalhamento em janeiro em relação a julho.




Figura 31: Plantação de eucalipto em diferentes situações de corte. A) cortado entre julho de 2008 e janeiro de 2009; B) estava sendo cortado em janeiro de 2009; C) não foi cortado.

Há também outra situação que, aparentemente, influencia o espalhamento no eucalipto que é a sua idade. A Figura 32 mostra a composição colorida de duas regiões com idade, aparentemente diferentes, notado pela espessura dos troncos e a ramificação dos galhos.




Figura 32: Eucaliptos em diferentes estagio de crescimento.

7.4.1.7. Cítricas

A plantação de cítricas é uma cultura permanente, ou seja, possui um ciclo de vida longo, em torno de 10 anos. Isso implica dizer que a abordagem de análise temporal empregada nessa pesquisa não é possível identificar mudanças na cultura, a não ser que haja corte da plantação, ou que tenha sido plantada recentemente. Portanto o retroespalhamento nos períodos analisados não sofre variações significativas (Figura 33). Esse alvo é formado por árvores com altura média de 4 m quando já desenvolvida. Sua estrutura forma um volume difuso e, assim como o eucalipto, é plantado de maneira alinhada com espaçamento constante o que faz com que o número de galhos e volume da copa não seja tão grande quanto da mata natural. Assim, o espalhamento volumétrico não é tão intenso quanto na mata natural. Isso é visto na polarização HV.




Figura 33: Retroespalhamento das cítricas nas polarizações HH e HV durante o período de análise.

7.4.1.8. Área urbana

A área urbana presente na região de estudo é formada apenas por edificações pertencentes ao município de São Pedro sendo constituída por casas e construções baixas. Alguns bairros são formados por menor densidade de edificações e na região central as construções estão mais próximas entre si.

O retroespalhamento na polarização HH em áreas de menor densidade de ocupação não é alto, pois há uma grande parcela dessa área descoberta nessas regiões, ou seja sem edificação e vegetação com a predominância de gramíneas e de solo exposto, sendo que ambos interagem de forma similar com a REM emitida pelo sistema ALOS/PALSAR. Na região central as construções são mais próximas, então o retroespalhamento é maior que na situação anterior. No entanto, quando o arruamento está direcionado perpendicularmente ao imageamento do sensor, ou seja, paralelo a linha de voo do sensor, o retroespalhamento aumenta consideravelmente. Isso é chamado de efeito cardeal e é notado na polarização HH e mostrado na Figura 34.









Figura 34: A) bairro com espaçamento grande entre as casas. B) região central da área urbana

A Tabela 10 apresenta de forma resumida a caracterização das classes descritas anteriormente.

Tabela 10: Resumo da caracterização das classes a serem mapeadas.

Cana de açúcar 	- Alta variação temporal; - altura máxima de aproximadamente 3m; - hastes finas e folhas alongadas - Diversificada interação com a onda da banda L (23.6cm)
Reservatório, rios e lagos 	- Praticamente não se altera ao longo do tempo; - parte da área estreita e meandrante, parte é largo (reservatório); -sofre reflexão especular
Gramínea 	- Baixa variação temporal; - estatura geralmente menor que 30 cm. - baixa interação com a onda da banda L (23.6cm)
Mata natural 	- Baixa variação temporal - Altura média de 10m; - Grande volume de galhos; - Presente em propriedade rural, Cuesta e zona ripária - Grande interação com a onda da banda L (23.6cm)
Vegetação de área úmida 	- sofre variação temporal em função dos períodos chuvosos - predominantemente herbácea - está no mesmo nível da água
Plantação de Eucaliptos 	- Árvores com altura entre 15m e 20m; - espaçamento constante entre as arvores- 3m x 3m; - ciclo de vida longo (5 a 10 anos) - baixa variação temporal, exceto quando há corte.
Plantação de cítricas 	- Cultura permanente- ciclo de vida em torno de 10 anos; - Baixa variação temporal; - Altura média 4m quando já desenvolvido; - espaçamento constante entre as arvores- 3m x 3m;
Área urbana 	- Casas e construções baixas; -Formado regiões com edificações mais próximas e regiões com edificações mais espaçadas; -algumas feições lineares ortogonais ao imageamento.

7.4.2. Classificação

Os resultados apresentados nessa sessão são referentes à fase 2 do processo de classificação e os limiares apresentados estão relacionados aos retroespalhamento do sinal dado em sigma 0 (dB). A conversão de amplitude para sigma zero foi realizada aplicando a Equação (SHIMADA et al., 2006): $\sigma^0 = 10 \cdot \log_{10} (DN^2) + CF$, onde DN é o nível de cinza (*Digital Number*) da imagem em amplitude e CF, o fator de conversão para o dado em amplitude, cujo valor para a cena HHabr08 é -83,4, HHjul08 é -83,2, HHjul08 é -80,2 e HHjan09 é -83. Foram selecionadas amostras de cada classe e gerado o BOXPLOT para cada polarização e as diferenças entre elas. A partir desses dados iniciou-se o processo de ajustar os limiares das polarizações para cada classe no eCognition. Esse procedimento é feito de maneira iterativa permitindo também a visualização dos objetos dentro do limite estabelecido. Desta forma, as regras foram elaboradas utilizando as polarizações mais adequadas para o mapeamento das classes.

A partir da análise do BOXPLOT do brilho médio dos objetos (Figura 35) foram criados 3 grupos abstratos – brilhante, escuro, médio- em referência à intensidade do retroespalhamento dos alvos.




Figura 35: BOXPLOT do brilho médio do retroespalhamento nos objetos amostrais de cada classe, permitindo a divisão em três grupos amostrais indicados – Brilhante, Médio, Escuro.

Além desses grupos foi criada a classe abstrata pertencente a classe mata natural denominada “mata da cuesta”, pois o retroespalhamento da mata natural nessas regiões sofre saturação do sinal pelo fato de estar na face da cuesta que está paralela a linha de vôo do sensor. As classes mapeadas dentro dos grupos abstratos de classificação são mostradas na Figura 36.

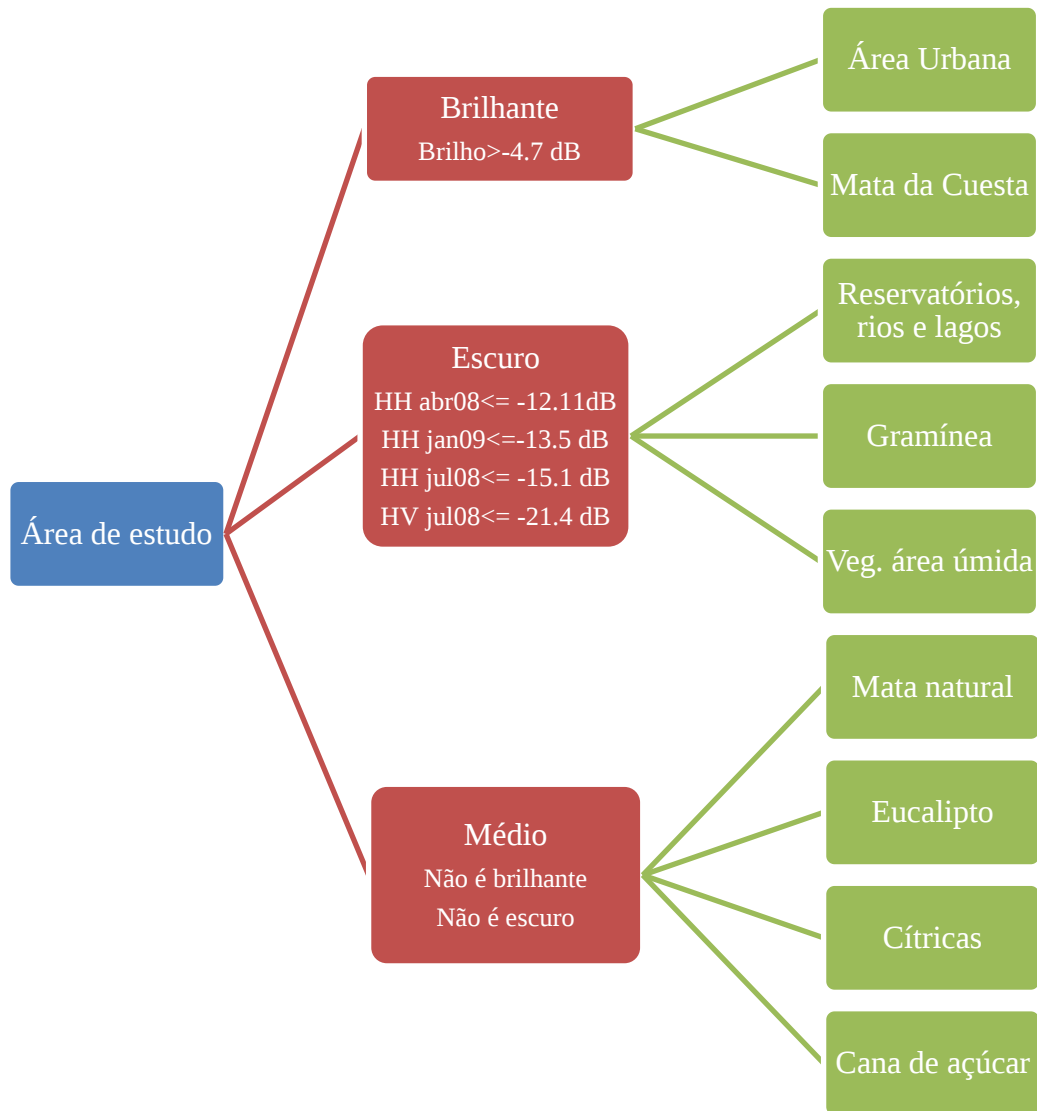



Figura 36: Grupos abstratos da classificação.

O BOXPLOT de cada polarização utilizado como base para a definição dos limiares dos conjuntos de regras é apresentado na Figura 37.






Figura 37: BOXPLOT de cada polarização dos objetos amostrais para cada classe a ser mapeada.

Existem diferenças dentro de algumas classes como a cana de açúcar, as cítricas e o eucalipto como já mencionado anteriormente na descrição de cada classe. Desta maneira foi feito o BOXPLOT dessas classes com seus grupos e sua variação no tempo (Figura 38). A partir dessas características e baseado nesse dado foram elaboradas as regras para cada classe.




Figura 38: BOXPLOT das classes cana de açúcar, cítricas e eucaliptos mostrando suas variações no tempo.

Para o mapeamento de algumas classes o atributo aspecto foi utilizado, pois fornece a informação de orientação das vertentes do relevo. Essa informação é importante para identificar em quais regiões estão voltadas para a direção de imageamento do sensor. A Figura 39 mostra um exemplo do aspecto e a indicação das vertentes voltadas para o imageamento e as que estão na situação oposta.




Figura 39: A) Exemplo do atributo aspecto; B) Verde e azul são regiões que não estão voltadas para o imageamento- aspecto não está entre 171 e 351.

O mapeamento do grupo brilhante engloba os objetos cujo retroespalhamento teve um retroespalhamento médio em HH de -4.7dB. Esse valor elevado decorre de serem regiões ou feições que se encontram ortogonais a linha de imageamento do sensor. Essas regiões estão em destaque na Figura 40 e são os alvos das classes “mata da cuesta” e “área urbana” a serem mapeados dentro desse grupo.




Figura 40: Regiões do grupo brilhante.

Destacando a região referente a mata de cuesta na Figura 41-A, pode-se notar que na cuesta há áreas com tons bem claros e tons escuros. Os tons claros ($HH \geq -4.7\text{dB}$) correspondem a vertente da cuesta ortogonal a direção de imageamento do sensor. A Figura 41-B mostra um ponto de vista aproximado da direção de imageamento do sensor. Os tons escuros correspondem ao lado oposto ao da situação descrita anteriormente, ou seja, a área de “sombra” em que o sinal chegou com menos intensidade, portanto o retroespalhamento é mais baixo, sendo que em HV jul08 variou entre -21 dB e -17 dB e em HH jul08 entre -18dB e -12dB. A Figura 41-B mostra o ponto de vista em 3D aproximado dessa região. Nessa Figura 41 também pode-se notar a grande declividade dessa área e essa característica (declividade maior que 15) foi utilizada para separar essa classe da área urbana




Figura 41: Pontos de vista da região da cuesta. As setas azuis indicam a região voltada para a orientação do imageamento e as setas vermelhas a região oposta.

Na área urbana o que provoca esse efeito é a orientação das feições lineares dado principalmente pelas ruas como já descrito anteriormente.

Desta forma para separar essas duas classes foi utilizada a característica de que o retroespalhamento na polarização HV na área urbana não é alta como na área de mata natural na cuesta, pois não ocorre o espalhamento volumétrico e sim a reflexão de canto em superfícies diédricas o que é caracterizado na polarização HH. Isso é expresso na relação HH-HV jul com retroespalhamento maior que -12.5 dB e HV jul08 variando entre -17.92 dB e -11.63 dB Além disso, a declividade de áreas urbanas não é tão alta quanto na vertente da cuesta (declividade > 15) onde está a mata natural (Figura 42). Porém, apenas a região correspondente aos valores muito altos de retroespalhamento da área urbana foi mapeada com essas regras. As demais regiões foram bastante confundidas com a mata natural e eucalipto. Para minimizar esse problema foi utilizada uma regra de refinamento dessa classe levando em consideração a vizinhança com a área urbana já mapeada. Essa regra mapeia objetos cuja borda relativa à área urbana > 0 , tenha HH abr08 ≥ -7.5 dB e HH jan09 ≥ -7.5 dB




Figura 42: Regiões de mata na cuesta no lado esquerdo e de área urbana no lado direito da imagem

Os demais objetos que foram mapeados no grupo brilhante, pois também estavam ortogonais a linha de imageamento e que não pertencem nem a classe mata da cuesta e nem

área urbana foram posteriormente alocado para suas respectivas classes na etapa de refinamento.

Após o mapeamento das classes do grupo brilhante foi mapeado o grupo escuro e posteriormente as classes reservatórios, rios e lagos, gramínea e vegetação úmida. Pertencem ao grupo escuro aqueles objetos que possuem retroespalhamento baixo em todas as polarizações HH, sendo $HH_{abr08} \leq -12.11\text{dB}$, $HH_{jan09} \leq -13.5\text{ dB}$, $HH_{jul08} \leq -15.1\text{ dB}$ e em HV também ($HV_{jul08} \leq -21.4\text{ dB}$).

Dentro do grupo escuro os objetos pertencentes a classe reservatórios, rios e lagos foram mapeados como sendo os que possuíam os menores valores de retroespalhamento em todas as polarizações, devido ao espalhamento especular que o sinal sofre ao atingir a água. Desta forma, os limiares na polarização HH para essa classe foram menor que -18.7dB em janeiro. Outro atributo utilizado para o mapeamento dessa classe foi a baixa densidade (menor que 1,3) dos objetos nas áreas meandricas do curso d'água (Figura 43).




Figura 43: Mapeamento da classe reservatórios, rios e lagos

Outra classe mapeada dentro do grupo escuro foi a gramínea. De acordo com as características dessa classe os limiares das polarizações foram baixos, porém maior que a água. O maior limiar do retroespalhamento utilizado para essa classe foi de -13.17dB a polarização HH de janeiro de 2009 e o menor limiar foi de -15.35dB em HH de julho de 2008. Isso era esperado uma vez que a gramínea sofre poucas alterações ao longo do tempo e há pouca interação com o sinal de radar da banda L com comprimento de 23.6 cm . Essa pequena diferença entre janeiro e julho pode ser explicado pela presença maior de umidade no solo em janeiro que é o período chuvoso na região do que em julho que está num período mais seco do ano. A Figura 11 apresenta a informação de que em janeiro houve maior precipitação do que em julho. Um exemplo da classificação da gramínea é mostrado na Figura 44. .




Figura 44: Exemplo do resultado da classificação da gramínea.

Uma parte da vegetação de área úmida foi mapeada dentro da classe escuro, pois esteve presente no período chuvoso (abril/08 ou janeiro/09) e não em todos os períodos de monitoramento. Desta maneira, o seu mapeamento foi feito considerando o retroespalhamento em HH de abril/08 variando entre -22 dB e -14.6 dB ou o retroespalhamento em HH de janeiro/09 variando entre -19dB e -12dB. Concomitante a essas regras também foi utilizado o DSM em relação aos reservatórios, rio e lagos maior que 0.98. A Figura 45 mostra esse mapeamento.




Figura 45: Resultado parcial da classificação da vegetação de área úmida.

O grupo médio foi mapeado como sendo todos aqueles objetos que não pertencem ao grupo brilhante nem o escuro. Os alvos que fazem parte desse grupo são aqueles que mais possuem variação temporal durante o período de monitoramento.

A primeira classe a ser mapeada dentro desse grupo foi a mata natural. Para essa classe foi necessário mais de uma regra para mapear toda a área de mata natural. Uma regra foi para mapear da mata natural da vertente da cuesta onde o sinal não chegou com muita intensidade caracterizado pela declividade maior que 15 e possuir retroespalhamento bastante diferente das características de mata natural como HV jul08 variando entre -21 dB e -17dB

Outro conjunto de regras foi utilizado para a mata natural densa com retroespalhamento em HV jul08 entre -14.6dB e -8dB e as polarizações em HH variaram entre -11dB e -6.6dB. Isso mostra que não há variação temporal nesta classe. Outros dois conjuntos de regras foram elaborados para as áreas de mata natural caracterizadas por estarem nas vertentes e serem mais esparsas. A diferenciação entre as áreas localizadas nas vertentes ortogonais à linha de imageamento e as vertentes opostas foi feita pelo atributo aspecto, sendo que as primeiras tem o aspecto variando entre 171.84 e 351.84 e a segunda são das demais vertentes. Foram considerados esses valores, pelo fato de a plataforma ALOS possuir uma rotação de 98.16°. O retroespalhamento nas áreas ortogonais é maior que na área oposta como, por exemplo, o HV jul08 variou entre -13.2 dB e 10.5 dB nas ortogonais e entre -14.8 e -17dB nas demais. A Figura 46 mostra essa situação




Figura 46: Mata natural na vertente oposta a linha de imageamento.

Após a aplicação dessas regras tem-se um exemplo do resultado dessa classificação na Figura 47. Porém houve alguns erros de classificação como apontado na Figura 47 em que alguns objetos pertencentes a classe cítricas foram classificados como mata natural. Esses erros estão indicados, na figura, pelas setas em vermelho.




Figura 47: Exemplo da classificação da mata natural

A próxima classe mapeada foram as plantações de eucaliptos. As regras para essa classificação foram baseadas em 3 diferentes grupos de eucaliptos presentes na região que podem estar relacionados ao volume e ao número de ramificações dos galhos e com a idade dos eucaliptos, uma vez que alguns eucaliptos tinham sido cortados na última data do monitoramento. Dessa maneira a região de eucalipto que ocorreu o corte apresentou retroespalhamento na polarização HH em janeiro mais baixo que nas demais datas anteriores, sendo que em janeiro variou entre -12.8dB e -15.8dB e em abril e julho ficou entre -7.5 dB e 12.7 dB. Uma das regras utilizada para o mapeamento dessa situação foi a diferença entre janeiro e julho e esta foi de até -5 dB, o que mostra a variação temporal. Além disso, a resposta em HV ficou entre -16 dB e -18.5 dB. A Figura 48 mostra essa situação e o resultado da classificação. É possível observar alguns pontos falhos na classificação, mas que foram corrigidas na etapa de refinamento.




Figura 48: Classificação do eucalipto que foi cortado em janeiro de 2009.

Há outras regiões na área de estudo em que o eucalipto presente é aparentemente mais jovem com menor volume de galhos que a situação anterior e não foi cortado durante o período em que foram adquiridos os dados. Desta forma, o conjunto de regras elaborado para

mapear essas áreas utiliza o limiar de maior que -10.4 dB para abril/08 e -10 dB para janeiro/09, podendo observar que não houve variação temporal entre as datas de análise. O resultado da classificação é mostrado na Figura 49.




Figura 49: Classificação de eucalipto mais jovem.

No entanto algumas áreas de plantio de eucalipto não foram mapeadas corretamente, pois se confundiam com plantação de cítricas, pois, provavelmente, o volume dos galhos e o alinhamento com que ambas são plantadas provoca a semelhança de seus retroespalhamento (Figura 50).




Figura 50: Região em que o eucalipto confunde-se com cítricas.

A classe cana de açúcar tem como característica principal a grande variação em um tempo relativamente pequeno, apresentando grande variação no tamanho e concentração das folhas. Desta maneira, as regras foram todas baseadas nas diferenças de retroespalhamento na polarização HH entre as datas. Alguns talhões de cana que variaram entre julho e abril foram mapeados quando $(HH \text{ jul08} - HH \text{ abr08})$ foi menor que -4.8dB ou maior que 2.8dB. Os talhões que mudaram entre julho e janeiro foram mapeados quando $(HH$

jan09 – HH jul08) foi menor que -2.8dB ou maior que 2.8dB. Os talhões que não mudaram entre abril e julho, mas sim entre abril e janeiro utilizou-se a regra de (HH jan09 – HH abr08) foi menor que -3.2dB ou maior que 3.2 dB. A Figura 51 mostra exemplos do resultado da classificação da cana de açúcar.




Figura 51: Exemplos da classificação da cana de açúcar.

As regras para a classificação das citricas precisou ser dividida em duas partes, pois a resposta das plantações de citricas com pés grandes, adultos com copas maiores e com maior numero de galhos é diferente das áreas em que o cítricos ainda está em crescimento. A primeira situação foi mapeada com regra que considera o retroespalhamento parecido nas polarizações HH, todas variando entre -6.5 dB e -12 dB e o HV entre -14.8 dB e -19.9 dB. Porém essa situação de plantação de cítricos confundiu-se um pouco com a plantação de eucaliptos como já mencionado anteriormente. Na segunda situação, em que o cítricos está crescendo, o solo influencia no retroespalhamento dessas áreas, pois as copas ainda não cobrem todo o dossel. Desta maneira, seus limiares são mais baixos, principalmente a polarização HV variando entre -19.8 dB e -23.3 dB que corresponde ao espalhamento volumétrico. No entanto, as regras para esse estágio do cítricos confundiu-se com áreas de cana de açúcar e também com a vegetação ciliar natural que não foram mapeadas por suas regras. Assim, essa classe foi mais difícil de ser mapeada. Na Figura 52 tem-se um exemplo

do mapeamento dessa classe sem passar pela etapa de refinamento e um exemplo onde ela foi confundida com cana de açúcar.




Figura 52: A) Exemplo da classificação de cítricas; B) exemplo da classificação de cana de açúcar como cítricas.

Todas as regras da classificação estão detalhadas no apêndice A.

7.4.3. Refinamento

Após o processo de classificação foi feito o seu refinamento de modo que os objetos que não foram classificados fossem designados à sua respectiva classe. Essa etapa basicamente utilizou-se das relações de vizinhança, tanto de borda, área e distância, associado a um limiar de retroespalhamento em alguma polarização. Essas regras são apresentadas a seguir para cada classe.

ÁREA URBANA

Objetos com borda relativa à área urbana > 0 e $HH_{abr08} \geq -7.5 \text{ dB}$ e $HH_{jan09} \geq -7.5 \text{ dB}$

RESERVATÓRIOS, RIOS E LAGOS

Objetos da classe Escuro com borda relativa a Reservatórios, rios e lagos ≥ 0.4

ou

DSM em relação a água > 0.98 e HV jul08 ≤ -23 dB

VEGETAÇÃO DE ÁREA ÚMIDA

Objetos da classe Escuro com borda para Reservatórios, rios e lagos ≥ 5 *pixels* e
borda para vegetação de área úmida ≥ 10 *pixels*

ou

Objetos da classe Escuro com borda relativa a vegetação de área úmida ≥ 0.3

ou

DSM em relação a água > 0.98 e HV jul08 > -23 dB

GRAMÍNEA

Objetos não classificados com HH abr08 ≥ -9.6 dB e DSM em relação a água ≤ 0.98

MATA NATURAL

Objetos não classificados com borda relativa a Mata natural > 0 e HV jul08 ≥ -18.7 dB

ou

Comprimento/largura ≥ 2 e HV jul08 ≥ 17.1 dB e (HH jan09 – HH jul) ≥ -3.5 dB

EUCALIPTOS

-17 dB $\leq$ HV jul08 ≤ -13.5 dB e 0.2 dB $\leq$ (HH jan09 – HH abr08) ≤ 3.8 dB
e -10.6 dB $\leq$ HH jul08 ≤ -5.3 dB

ou

5.5 dB $\leq$ HH-HV jul 08 ≤ 6.7 dB e -18.6 dB $\leq$ HV jul08 ≤ -17 dB e -0.75 dB $\leq$ (HH jan09 – HH jul08) ≤ 1.3 dB

CANA DE AÇÚCAR

Borda relativa a cana de açúcar ≥ 0.4 e (HH jan09 – HH abr08) ≤ -2 dB e
(HH jan09 – HH abr08) ≥ 2 dB

CÍTRICAS

Objetos não classificados com $HV_{jul08} \leq -17\text{dB}$ e $HV_{jul08} \geq -20\text{dB}$
ou

Objetos não classificados com borda relativa à Cítricas ≥ 0.25

Após a aplicação das regras para o refinamento da classificação tem-se o resultado apresentado na Figura 53.




Figura 53: Resultado final após a aplicação de todas as regras de classificação e refinamento.

Observando o resultado final o ruído característico de imagens SAR, *speckle*, o qual introduz na imagem um aspecto granuloso, está praticamente ausente na classificação, pois na abordagem adotada nesse trabalho a análise é feita a partir do objeto e não mais de um único pixel (Figura 54).




Figura 54: Classificação com ausência do *speckle*.

7.5. Avaliação da classificação

Após todo o processo de classificação o resultado final foi comparado com os dados de referência. A amostragem sistemática não alinhada produziu 593 Elementos cuja correspondência foi avaliada para produzir uma matriz de erro. Essa matriz de erro é mostrado na Tabela 11.

Tabela 11: Matriz de erro da classificação final.

Classificação	Dados de referência									Acurácia usuário (%)
	Eucal.	Cítricas	veg área umida	Área urb.	Res/rios/lagos	Gram.	Mata nat.	Cana	Total	
Eucal.	13	0	0	0	0	0	0	0	13	100,0
Cítricas	1	20	1	2	0	2	2	1	29	68,9
veg área umida	0	0	20	0	0	0	0	1	21	95,2
Área urb.	0	0	0	8	0	0	1	0	9	88,9
Res/rios/lagos	0	0	1	0	8	0	0	0	9	88,9
Gram.	0	0	0	1	0	149	6	11	167	89,2
Mata nat.	3	1	3	8	0	7	140	10	172	81,4
Cana	3	0	0	0	1	6	6	117	133	87,9
Total	20	21	25	19	9	164	155	140	553	
Acurácia do produtor (%)	65,0	95,2	80,0	42,1	88,9	90,8	90,3	83,6		
Acurácia global	85,6%									
Coeficiente Kappa	0,81									

A acurácia global da classificação foi de 85,6% o que significa dizer que 14,4% dos objetos amostrados foram classificados de maneira errada. O coeficiente Kappa obtido a partir dessa matriz de erro foi de 0,81.

Apesar dos bons resultados expressos pela acurácia global e pelo coeficiente *Kappa*, é importante analisar a acurácia do produtor e do usuário para cada classe, pois expressam os erros de omissão e comissão, respectivamente. A classe que apresentou a menor acurácia do produtor foi a área urbana com 42,1%, o que significa dizer que de todos os dados

de referência apenas 42,1% foram classificados corretamente. Esse resultado era esperado pela dificuldade de mapear as regiões menos densas de área urbana, onde a confusão entre a mata natural e essa classe pode ser pela maior quantidade de árvores nessas regiões. A segunda menor acurácia do produtor foi apresentada pela classe eucalipto (65%) e também era esperado pela dificuldade de separar esta classe das cítricas como já mencionado anteriormente. Em contrapartida, as classes que apresentaram as maiores acurácias do produtor foram cítricas (95,2%), gramínea (90,8%) e mata natural (90,3%). Apesar de as cítricas terem apresentado alta acurácia do produtor, ou seja, houve concordância entre os dados de referência e o classificado, ela também apresentou a menor acurácia do usuário, portanto objetos pertencentes a outras classes foram classificados como sendo cítricas. A classe gramínea apresentou retroespalhamento baixo e bastante diferente das demais classes. As pequenas confusões ocorridas entre a gramínea, mata natural e a cana de açúcar podem ser decorrentes de alguma regra de vizinhança. A vegetação de área úmida apresentou um resultado razoável confundindo-se com reservatórios, rios e lagos, o que pode ser explicado por erro na amostragem. Essa vegetação também confundiu-se com mata natural, pois onde a região está úmida o retroespalhamento é mais alto, parecido com a mata. A cana de açúcar teve uma boa acurácia do usuário e também boa acurácia do produtor (87,9%). É compreensível os erros ocorridos nesta classe por se tratar de um tipo de cultura que varia bastante no tempo e nem sempre os períodos de plantio/rebrota e colheita ocorrem nos períodos do ano esperado em toda a área, uma vez que os produtores desejam sempre manter a produção buscando alternativas para isso. O que poderia melhorar a detecção dessa classe seria a aquisição de dados em outros períodos do ano em que a cana de açúcar esteja em outros estágios de desenvolvimento como em novembro.

Algumas confusões que não eram esperadas devido a grandes diferenças no retroespalhamento entre algumas classes como, por exemplo, gramínea e mata natural podem ter ocorrido por falhas nas regras de relação com a vizinhança e devem ser corrigidas.

8. CONCLUSÕES E RECOMENDAÇÕES

O objetivo desse trabalho foi desenvolver um procedimento baseado na análise orientada a objetos para a classificação de imagens SAR na banda L (ALOS/ PALSAR). Os resultados obtidos com acurácia global de 85,6% pela aplicação da abordagem proposta juntamente com esse comprimento de onda em que a interação é maior com a estrutura dos alvos é adequado para identificação de vários tipos de cobertura da terra.

O uso do algoritmo de segmentação multiresolução permitiu a utilização de todas as polarizações para a criação dos objetos assim como a trabalhar com diferentes níveis de detalhes o que proporcionou a estratégia de mapear classes em diferentes níveis de acordo com a necessidade. Essa abordagem também permitiu a utilização das relações de vizinhança entre as classes o que ajudou na obtenção de bons resultados e sem o aspecto granuloso característico do *speckle*. Essa estratégia não poderia ser utilizada em análises convencionais que utilizam apenas as informações estatísticas.

É importante ressaltar a importância da análise temporal feita em um intervalo de tempo relativamente pequeno (9 meses), mas que englobasse as variações sazonais ocorridas na área. Algumas classes só puderam ser discriminadas a partir da aplicação do conhecimento do comportamento dos alvos em relação ao período de monitoramento, como por exemplo, a cana de açúcar.

O uso da elevação, declividade e aspecto derivados do PRISM DSM foram importantes para a identificação de classes como a vegetação aquática e a vegetação presente na front da cuesta. O aspecto foi importante para o mapeamento de regiões de uma mesma classe que apresentasse respostas diferentes devido ao seu posicionamento em relação a direção de imageamento do sensor.

Como recomendação a trabalhos futuros, os resultados podem ser melhorados utilizando a polarização dual (HH+HV) em dados obtidas nos períodos de novembro-dezembro, período intermediário de algumas culturas como a cana de açúcar, e março-abril, início da colheita da cana de açúcar, além da utilização de mais uma repetição de aquisição de dados no mesmo período de monitoramento.

Vale mais uma vez ressaltar que esse trabalho foi desenvolvido, em parte, no contexto da *JAXA Kyoto & Carbon Initiative*, contou com a colaboração de Takeo Tadono da JAXA EORC criando o PRISM DSM utilizado neste trabalho e com a JAXA EORC, a qual disponibilizou as imagens ALOS/PALSAR utilizadas.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR,D., SILVA, F.W., RUDORFF, B.F.T., SUGAWARA, L., CARVALHO, M.A. Expansão da cana-de-açúcar no Estado de São Paulo: safras 2003/2004 a 2008/2009. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 12., 2009, Natal. Anais... São José dos Campos: INPE, 2009.p. 9-16.

BAATZ, M., SCHÄPE, A. Multiresolution segmentation- an optimization approach for high quality multi-scale image segmentation. In: **Strobl, J., Blaschke, T., Griesebner, G. (Eds.), Angewandte Geographische Informationsverarbeitung XII**, Wichmann-Verlag, Heidelberg, pp. 12–23. 2000.

BENZ, U.BAATZ, M. SCHREIER, G. OSCAR-object oriented segmentation and classification of advanced radar allow automated information extraction. **Geoscience and Remote Sensing Symposium, 2001. IGARSS '01**. IEEE 2001 International. v.4. p. 1913 – 1915.

BENZ, U.C., HOFMANN, P.,WILLHAUCK, G., LINGENFELDER, I., HEYNEN,M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS J. Photogrammetry Remote Sensing** 58, 239–258.2004.

BLAES, X., VANHALLE, L., DEFOURNY, P. Efficiency of crop identification based on optical and SAR image time series. **Remote Sensing of Environment**, v. 96, n. 34, p. 352-365. 2005.

BRISCO, B., BROWN, R.J. Multidate SAR/TM synergism for crop classification in Western Canada. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 8, p. 1009-1014. 1995.

CALIJURI, M. C.(1988). **Respostas fisio-ecológicas da comunidade fitoplantônica e fatores ecológicos em ecossistemas com diferentes estágios de eutrofização**. São Carlos, Tese (Doutorado) EESC/USP, 293p.

CAMPBELL, JB.. **Introduction to Remote Sensing**. The Guildford Press, New York. 3. ed. 621p. 2002.

CARVALHO, F. T. et al. Plantas aquáticas e nível de infestação das espécies presentes no reservatório de Barra Bonita, no rio Tietê. *Planta Daninha*, v. 20, p. 15-19, 2003. (Edição Especial).

CONGALTON, R. G. 1988b. A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data. *Photogrammetric Engineering and Remote Sensing*. Vol. 54, No. 5, pp. 593–600.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: CRC Press, 2008. 183 p.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas, SP, Brasil: IG-UNICAMP, 1992. v. 1. 170 p.

DEFINIENS, AG. **Definiens Developer 7 User Guide**. Document version 7.0.7.936. Definiens AG, Munchen, Germany. 2007.

DEL FRATE, F., SCHIAVON, G., SOLIMINI, D., BORGEAUD, M., HOEKMAN, D. H., & VISSERS, M. A. M. (2003). Crop classification using multiconfiguration C-band SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, 41(7), 1611–1619.

DESCLEE, B., BOGAERT, P., DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**. v. 102 n. 1–2. p. 1–11. 2006.

DI GREGORIO, A. **Land Cover Classification System (LCCS)**, version 2: classification concepts and user manual. Rome: FAO, 2004.

DOBSON, M.C.; ULABY, F.T.; PIERCE, L.E. Land cover classification and estimation of terrain attributes using Synthetic Aperture Radar. **Remote Sensing of Environment**. v. 51, p.199-214. 1995.

ELACHI, C. **Introduction to Physics and Techniques of Remote Sensing**. New York. Wiley & Sons. , 1987.

ESPÍNDOLA, E. L. G. (1994). **Dinâmica da associação congênica das espécies de Notodiaptomus (Copépoda, Calanoida) no reservatório de Barra Bonita, São Paulo**. São Carlos, SP, 363p. Tese (Doutorado) - Ciências da Engenharia Ambiental, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 1994.

FOCKELMANN R. **Agricultural parcel detection with Definiens e-Cognition**. Disponível em: <http://www.definiens.com/article.php?id=20&link_id=15&sublink_id=16>. Acesso em 25 jun. 2009.

FONSECA , L. G. M. et al. **Apostila de processamento digital de imagens**. São José dos Campos: INPE, jun. 2000.

GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C. & CERRI, C. E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. *Remote Sensing of Environment*, 96, 366–374, 2005.

GENOVEZ, P., FREITAS, C. C., BENTZ, C.C., FREITAS, R. M., DUTRA, L.V. Detecção de óleo e ocorrências ambientais em imagens SAR: Avaliação de diferentes parâmetros de pré processamento e diferentes segmentadores. In: **XIV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**. Natal, Brasil. **Anais**. INPE, 2009 p. 6903-6910.

GOLTZ, E.; PINHO, C. M. D.; FONSECA, L. M. G.; RUDORFF, B. F. T.; AGUIAR, D. A. Classificação orientada a objeto na identificação de áreas de reforma de cana-de-açúcar. In: **SIMPÓSIO LATINO AMERICANO DE PERCEPÇÃO REMOTA (SELPER)**, 09, 2008, Havana – Cuba. Cd ROM.

HAJNSEK, I.; PAPATHANASSIOU, K. **Rough surface scattering models**. 2005. Disponível em http://earth.esa.int/polsarpro/Manuals/2_Rough_Surface_Scattering_Models.pdf.

HENDERSON, F. M.; LEWIS, A. J. **Manual of remote sensing: principles and applications of imaging radar**, 3 ed, John Wiley Sons, USA, v. 2, 896p, 1998.

HESS, L. L., MELACK, J. M., NOVO, E. M. L. M., BARBOSA, C. C. F., & GASTIL, M. Dual-season mapping of wetland inundation and vegetation for the central Amazon basin. **Remote Sensing of Environment**. v. 87, p. 404–428. 2003.

JAXA. **ALOS user handbook**. 2007. Disponível em <http://www.eorc.jaxa.jp/ALOS/en/doc/handbk.htm>. Acesso em 20 de out. 2008.

JENSEN, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução Jose Carlos Neves Epiphany (coordenador) et al.- São Jose dos Campos, SP. Parenteses, 2009.

LANG, S. 2008. **Object-based image analysis- special concepts for knowledge-driven remote sensing applications**. Springer. 2008.

LEBERL, F. W. Radargrammetry, in **Principles & Applications of Imaging Radar**, Manual of Remote Sensing, 3rd Edition, Editors F, 1998.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 1987. 721p.

LUCAS, R.; ROWLANDS, A.; BROWN, A.; KEYWORTH, S.; BUNTING, P.. Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 3, p. 165-185. 2007.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**, 2 ed. Chichester: John Wiley & Sons, 1999. 292 p.

MIKHAIL, E. M., BETHEL, J.S., McGLONE, C. **Introduction to modern photogrammetry**, NY: John Wiley, p. 479.

NASCIMENTO, P. S.R; GARCIA, G. J. Atualização do mapa de vegetação natural e do uso da terra na sub-bacia do Baixo Piracicaba (SP) com o auxílio de imagens TM/LANDSAT-5. **Estudos Geográficos**, Rio Claro, 2(2): 31-45, dezembro – 2004.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. 1. ed. USA. CRC press. 2006. 165.

RIBEIRO, S. A.; SANTOS, D. R. E CENTENO, J. S. Aplicação da Metodologia de Dados Orientado a Objeto na Classificação de uma Área Urbanizada, Utilizando uma Imagem Digital Obtida por meio da Tecnologia do Laser Scanner. In: **ANAIS I SIMPÓSIO BRASILEIRO DE GEOMÁTICA**. Presidente Prudente. 2002.

RICHARDS, J. A. **Remote Sensing Digital Image Analysis**. Berlin, Germany: Springer-Verlag, p. 250. 1999.

ROGAN, J., CHEN, D. **Remote sensing technology for mapping and monitoring land-cover and land-use change**. Elsevier. v.61, 301-325. 2004.

ROSA, R. **Introdução ao sensoriamento remoto**. 5 ed., Uberlândia: EDUFU, 2003, 228p.

RYHERD, S., WOODCOCK, C. E. Combining spectral and texture data in the segmentation of remotely sensed images. **Photogrammetric Engineering and Remote Sensing**. v. 62 n. 2, 181– 194. 1996.

SCOFIELD, G.B, DUTRA, L.V. SILVA,D.L.A., NEGRI, R.G., ABOUND, S.R., FREITAS, C. C. Mapeamento da cobertura da terra na Floresta Nacional de Tapajós – PA utilizando imagem de coerência polarimétrica. In: **XIV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**. Natal, Brasil. **Anais**. INPE, 2009 p. 6227-6232.

SHIMADA, M., ITO, N., WATANABE, M., MORIYAMA, T., TADONO, T. “**PALSAR initial calibration and validation results**,” Proc. SPIE, pp. 6359–6367, Set. 2006.

SKRIVER, H. Comparison between multitemporal and polarimetric sar data for land cover classification. **Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008**. IEEE International. v.3. p. 558-568.2008.

SOUSA Jr, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. 133p. Tese de Doutorado em Computação Aplicada. Instituto Nacional de Pesquisas Espaciais. 2005.


STEFANOV, W.L.; RAMSEY, M.S.; CHRISTENSEN, P.R. Monitoring urban land cover change: an expert system approach to land cover classification of semiarid to arid urban centers. **Remote Sensing of Environment**, v.77, p.173– 185, 2001.

STORY, M.; CONGALTON, R. G. Accuracy assesment: a user’s perspective. **Photogrammetric engineering and remote sensing**, v. 52, n.3, p.397-399, 1986.

ULABY, F. T., MOORE, R. K., & FUNG, A. K. Microwave remote sensing: active and passive. **From theory to applications**, Vol. 3. Boston, London: Artech House 1098 pp. 1986
União da Indústria de Cana-de-açúcar (UNICA). Dados e Cotações – Estatísticas, Produção Brasil. 2009. Disponível em <<http://www.unica.com.br/dadosCotacao/estatistica/>>. Acesso em: 18 nov 2009.

WASKE, B., BRAUN, M. Classifier ensembles for land cover mapping using multitemporal SAR imagery. **Journal of Photogrammetry and Remote Sensing**. v.64 p.450-457. 2009.

APÊNDICE A- Regras para a classificação das diferentes coberturas da terra.



BRILHANTE

ÁREA URBANA (Hi)

Jul HH-HV>= 12.5 d e HH abr08>= -2.57 dB e -17.92dB<HV jul08<-11.63 dB

MATA DA CUESTA

slope>20

ESCURO**RESERVATÓRIOS, RIOS E LAGOS**

HH abr08 <= -20.37 dB e HH jan09 <= -18.7 dB e HH jul08 <= -19.7 dB e slope <= 10

ou

Brilho <= -20.1 dB e Density <= 1.3 e DSM < 457m

GRAMÍNEA

HH abr08 <= -14.0 dB e HH jan09 <= -13.17 dB e HH jul08 <= -15.35 dB e HV jul08 <= -21.7 dB

VEG. ÁREA ÚMIDA

DSM < 456m

e

-22 dB <= HH abr08 <= -14.6 dB ou -19 dB <= HH jan09 <= -12 dB

MÉDIO**MATA NATURAL**

DSM em relação a água <= 0.988

e

Slope > 15 e -21 dB <= HV jul08 <= -17 dB e -18 dB <= HH jul08 <= -12 dB

Ou

171 <= Aspecto <= 351 e -9.7 dB <= HH abr08 <= -4 dB e -13.2 dB <= HV jul08 <= -10.5 dB e -10.3 dB <= HH jan09 <= -4.2 dB e -10.9 dB <= HH jul08 <= -4.7 dB

ou

Aspecto <= 171 e Aspecto >= 351 e -12.7 dB <= HH abr08 <= -9.9 dB e -17 dB <= HV jul08 <= -14.8 dB e -13.5 dB <= HH jan09 <= -9.3 dB e -12.9 dB <= HH jul08 <= -10.1 dB

ou

-10.7 dB <= HH abr08 <= -6.7 dB e -14.6 dB <= HV jul08 <= -8 dB e -10.8 dB <= HH jan09 <= -6.6 dB e -11 dB <= HH Jul08 <= -6.6 dB

EUCALIPTO

DSM em relação a água ≤ 0.988

e

$HH\ abr08 \geq -10.4\ dB$ e $HH\ jan09 \geq -10\ dB$ e $HH\ jul08 \geq -11.1\ dB$ e $-18.2\ dB \leq HV\ jul08 \leq -16.81\ dB$

ou

$-5\ dB \leq (HH\ jan09 - HH\ jul08) \leq -1.8\ dB$ e $5.42\ dB \leq HH - HV\ jul08 \leq 7.75\ dB$ e $-15.8\ dB \leq HH\ jan09 \leq -12.8\ dB$ e $-2.3\ dB \leq (HH\ jul08 - HH\ abr08) \geq 1.8\ dB$ e $-18.5\ dB \leq HV\ jul08 \leq -16\ dB$

CANA DE AÇÚCAR

DSM em relação a água ≤ 0.988

e

$-3.2\ dB \geq (HH\ jan09 - HH\ abr08) \geq 3.2\ dB$

ou

$-2.8\ dB \geq (HH\ jan09 - HH\ jul08) \geq 2.8\ dB$

ou

$-4.8\ dB \geq (HH\ jul08 - HH\ abr08) \geq 2.8\ dB$

ou

$HV\ jul08 \leq -17\ dB$ e $(HH\ jan09 - HH\ jul08) \geq 0.9\ dB$

CÍTRICAS

DSM em relação a água ≤ 0.988

e

$5.8\ dB \leq HH - HV\ jul08 \leq 7.8\ dB$ e $-23.3\ dB \leq HV\ jul08 \leq -19.8\ dB$ e $-14.79\ dB \leq HH\ jan09 \leq -11.6\ dB$

ou

$-10.8\ dB \leq HH\ abr08 \leq -6.5\ dB$ e $6.65\ dB \leq HH - HV\ jul08 \leq 8.5\ dB$ e $-19.9\ dB \leq HV\ jul08 \leq -14.8\ dB$ e $-12\ dB \leq HH\ jan09 \leq -7.2\ dB$ e $-11.5\ dB \leq HH\ jul08 \leq -7\ dB$ e $-2.5\ dB \geq (HH\ jul08 - HH\ abr08) \geq 1\ dB$

REGRAS DE REFINAMENTO DA CLASSIFICAÇÃO

ÁREA URBANA

Objetos com borda relativa à área urbana > 0 e $HH_{abr08} \geq -7.5 \text{ dB}$ e $HH_{jan09} \geq -7.5 \text{ dB}$

RESERVATÓRIOS, RIOS E LAGOS

Objetos da classe Escuro com borda relativa a Reservatórios, rios e lagos ≥ 0.4
ou
DSM em relação a água > 0.98 e $HV_{jul08} \leq -23 \text{ dB}$

VEGETAÇÃO DE ÁREA ÚMIDA

Objetos da classe Escuro com borda para Reservatórios, rios e lagos $\geq 5 \text{ pixels}$ e
borda para vegetação de área úmida $\geq 10 \text{ pixels}$
ou
Objetos da classe Escuro com borda relativa a vegetação de área úmida ≥ 0.3
ou
DSM em relação a água > 0.98 e $HV_{jul08} > -23 \text{ dB}$

GRAMÍNEA

Objetos não classificados com $HH_{abr08} \geq -9.6 \text{ dB}$ e DSM em relação à
água ≤ 0.98

MATA NATURAL

Objetos não classificados com borda relativa a Mata natural > 0 e $HV_{jul08} \geq -18.7 \text{ dB}$
ou
Comprimento/largura ≥ 2 e $HV_{jul08} \geq -17.1 \text{ dB}$ e $(HH_{jan09} - HH_{jul}) \geq -3.5 \text{ dB}$

EUCALIPTOS

$-17 \text{ dB} \leq \text{HV jul08} \leq -13.5 \text{ dB}$ e $0.2 \text{ dB} \leq (\text{HH jan09} - \text{HH abr08}) \leq 3.8 \text{ dB}$ e $-10.6 \text{ dB} \leq \text{HH jul08} \leq -5.3 \text{ dB}$

ou

$5.5 \text{ dB} \leq \text{HH-HV jul 08} \leq 6.7 \text{ dB}$ e $-18.6 \text{ dB} \leq \text{HV jul08} \leq -17 \text{ dB}$ e $-0.75 \text{ dB} \leq (\text{HH jan09} - \text{HH jul08}) \leq 1.3 \text{ dB}$

CANA DE AÇÚCAR

Borda relativa a cana de açúcar ≥ 0.4 e $(\text{HH jan09} - \text{HH abr08}) \leq -2 \text{ dB}$ e $(\text{HH jan09} - \text{HH abr08}) \geq 2 \text{ dB}$

CÍTRICAS

Objetos não classificados com $\text{HV jul08} \leq -17 \text{ dB}$ e $\text{HV jul08} \geq -20 \text{ dB}$

ou

Objetos não classificados com borda relativa à Cítricas ≥ 0.25