

Revista Brasileira de Cartografia (2015) N^o 67/7: 1391-1411
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

DISTÂNCIAS ESTOCÁSTICAS E MAPAS DE INCERTEZAS APLICADOS À CLASSIFICAÇÃO DE DADOS DE MÚLTIPLOS SENSORES

*Stochastic Distances and Uncertainties Maps Applied to
Multi Sources Data Classification*

**Bruna Cristina Braga¹, Sidnei João Siqueira Sant'Anna²
& Corina da Costa Freitas²**

**¹Instituto Nacional de Pesquisas Espaciais - INPE
Divisão de Sensoriamento Remoto – DSR**

Av. dos Astronautas 1758 - 12227-010 - São José dos Campos/SP, Brasil
bcbraga@dsr.inpe.br

**²Instituto Nacional de Pesquisas Espaciais - INPE
Divisão de Processamento de Imagens – DPI**

Av. dos Astronautas 1758 - 12227-010 - São José dos Campos/SP, Brasil
{sidnei, corina}@dpi.inpe.br

*Recebido em 27 de Fevereiro, 2015/ Aceito em 07 de Agosto, 2015
Received on February 27, 2015/ Accepted on August 07, 2015*

RESUMO

Neste trabalho é proposto o aperfeiçoamento de classificações por meio de uma nova técnica de integração de dados multifonte ou multisensor cuja combinação ocorre em nível diferente daqueles adotados em técnicas de integração tradicionais. Neste caso, a composição dos dados é aplicada às informações obtidas no processo de classificação individual de w imagens provenientes de w fontes distintas. O conteúdo dessas informações refere-se às distâncias e estatísticas de teste contidas nos mapas de incertezas (referentes à confiabilidade da classificação) de cada uma das classificações. Os dados selecionados para este trabalho contemplam uma imagem óptica e uma imagem de micro-ondas. Tais imagens foram classificadas a partir do classificador por regiões *PolClass* que além da classificação gera um mapa de incertezas. Por meio dos dados gerados nas classificações individuais das imagens foram construídos cinco Cenários de Classificação visando índices de acurácia superiores aqueles obtidos pelas classificações individuais. Dois destes Cenários de classificação apresentaram baixas incertezas nas classificações. Para um deles, o coeficiente *kappa* e acurácia global igualaram-se estatisticamente ao maior *kappa* e maior acurácia adquiridos individualmente. O outro Cenário, cuja origem foi baseada na lógica *Fuzzy*, obteve o melhor resultado entre os Cenários criados. A utilização de informações provenientes de fontes distintas mostrou-se um fator positivo na classificação por agregar diferentes informações ao resultado final. A lógica *Fuzzy* revelou-se um fator positivo por permitir uma classificação em classes mistas com baixas incertezas.

Palavras chaves: Classificação de Imagens, Distâncias Estocásticas, Dados Multifontes, Dados Multisensor, Mapa de Incertezas.

ABSTRACT

In this paper is proposed classification improvement through a new multi source or multi-sensor integration method whose combination is in different level those known in literature. At this rate, data integration occurs through the w image classification results from w different sources. The content of these reports refers to distances and test statistics contained in the uncertainty maps (regarding the reliability of the obtained classification) for each of the classifications. The data selected for this paper include a optical image and a microwave image. Such images were classified by the region based classifier *PolClass*, that besides the classification, the classifier generates an uncertainty map. Five Scenarios were established based on the individual classified images and their uncertain maps. Two of these Scenarios showed low uncertainties values. One of them presented the kappa coefficient and overall accuracy statistically equal to the highest values obtained individually. The other Scenario, based on Fuzzy logic, had the best result among all the Scenarios. The use of information from different sources proved to be a positive factor in land use and land cover classification. The use of fuzzy logic led to classification results with low uncertainty by allowing mixed classes.

Keywords: Image Classification, Stochastic Distances, Multi Sources Data, Multi-sensor Data, Uncertainty Maps.

1. INTRODUÇÃO

A grande demanda por conhecimento e monitoramento dos recursos naturais objetivando seu controle e utilização de forma consciente, tem impulsionado a execução de projetos de levantamento e mapeamento da superfície terrestre. Avanços nas áreas de sensoriamento remoto e geoprocessamento introduziram diversas ferramentas para execução desta tarefa, entre elas, a classificação de imagens provindas de sensores orbitais.

Com o advento dos sensores orbitais, grandes áreas puderam ser imageadas com certa periodicidade. Desta forma, tornou-se possível a realização de estudos em extensas regiões a um custo relativamente baixo (FREITAS *et al.*, 2003).

Em geral, os sensores podem ser especificados de acordo com a faixa do espectro eletromagnético em que operam. Os sensores ópticos, assim chamados por operarem na faixa óptica do espectro eletromagnético (0,30 a 15,0 μm), são os sensores nos quais os especialistas possuem maior experiência dentro do sensoriamento remoto. A necessidade de uma fonte externa de iluminação e a grande dependência das condições climáticas são algumas das desvantagens vinculadas ao uso destes sensores (FREITAS *et al.*, 2003).

Embora o imageamento por sistemas ópticos seja uma técnica madura em sensoriamento remoto, suas limitações conduzem à utilização de sensores operando em outras bandas do espectro eletromagnético. Entre estes se destacam os sensores de micro-ondas (GERSTL, 1990). Imagens provenientes destes sensores vêm sendo intensamente utilizadas uma vez que eles podem adquirir dados pouco influenciados pelas condições

climáticas, sem a necessidade da iluminação solar.

As características apresentadas pelos sensores de micro-ondas são interessantes, particularmente, para o estudo de regiões tropicais, onde o imageamento com sensores ópticos sofre grande restrição devido à alta probabilidade de ocorrência de nuvens. A presença de nuvens ocasiona a perda de informação pelo fato de não ser possível penetrá-las nesta faixa de energia ao contrário do que ocorre na faixa de micro-ondas. Por outro lado, imagens oriundas de sensores de micro-ondas são, de modo geral, visualmente menos ricas em informações e detalhes em comparação com as imagens ópticas, dificultando sua interpretação visual (FREITAS *et al.*, 2003).

Há anos, as diferenças significativas entre imagens ópticas e de micro-ondas, principalmente no que se refere ao comportamento dos dados, vem sendo observadas. Diversos trabalhos envolvendo a integração destes dados foram desenvolvidos em busca de benefícios decorrentes de suas características complementares (ULABY *et al.*, 1982; PARIS e KWONG, 1988; CHAVEZ *et al.*, 1991; SCHISTAD-SOLBERG *et al.*, 1994; HAACK *et al.*, 2000; TROUVÉ *et al.*, 2005; MOREIRA *et al.*, 2007; KUSSUL *et al.*, 2013; BYUN *et al.*, 2013; PEREIRA *et al.*, 2013; REICHE *et al.*, 2015; BRAGA *et al.*, 2015a; BRAGA *et al.*, 2015b). Alguns trabalhos envolvendo o mapeamento ou classificação do uso e cobertura da terra, desenvolvidos em regiões da Amazônia brasileira (LU *et al.*, 2011; PEREIRA *et al.*, 2013, FURTADO *et al.*, 2015) concluíram que a integração de informações provenientes de fontes ópticas e de micro-ondas pode apresentar resultados mais favoráveis do que aqueles obtidos

individualmente. Em tais trabalhos também são comparados e avaliados diferentes métodos de integração conhecidos na literatura.

Segundo Pohl e Van Genderen (1997), a integração de dados pode ocorrer basicamente de duas formas, pelo método da fusão de imagens ou pela combinação multisensor. Na fusão, integram-se os dados contidos em duas ou mais bandas de uma imagem para formar uma nova imagem sintética ou grupo de imagens enquanto na combinação, integram-se algoritmicamente w imagens de w canais diferentes, sem criar um novo conjunto de imagens.

Algumas limitações são associadas as técnicas de integração de dados tradicionais. Segundo Hall e Llinas (2000), uma imagem fusionada não substituirá uma imagem provinda de um sensor com ótimas especificações técnicas. Além disto, a fusão de imagens pode apresentar informações incorretas (artefatos). Os mesmos autores ainda afirmam que as técnicas de integração presentes na literatura não podem corrigir erros oriundos do processamento individual das imagens e, de forma geral, não existe um método de integração de dados excelente, embora, diversos estudos estejam sendo realizados em busca de melhorias nas técnicas já existentes além da busca por novos métodos de integração.

Neste trabalho é, então, proposto o aperfeiçoamento de classificações por meio de uma nova técnica de combinação de dados multisensor cuja integração ocorre em níveis diferentes daqueles adotados em técnicas de integração tradicionais. Neste caso, a integração dos dados é aplicada às informações contidas em classificações individuais de w imagens provenientes de w fontes distintas.

O aprimoramento dos resultados de classificação será realizado por intermédio da integração de informações relativas às distâncias e estatísticas de teste contidas nos mapas de incertezas das classificações individuais de imagens derivadas de fontes distintas (múltiplos sensores). Diferente da operação de fusão, em que, em geral, uma nova imagem é sintetizada a partir das imagens originais (POHL e VAN GENDEREN, 1997), a abordagem proposta utilizará as informações obtidas a partir das classificações de w imagens de múltiplos sensores, e construirá uma nova classificação com índices de acurácia superiores aqueles obtidos pelas classificações individuais.

As classificações individuais são geradas por meio do classificador por regiões **PolClass**. A nova classificação e seu mapa de incertezas são construídos através dos elementos estatísticos computados no procedimento de classificação individual.

A abordagem de classificação adotada para este trabalho refere-se à classificação por regiões supervisionada. Um dos mais clássicos tratamentos empregados na classificação por regiões utiliza distâncias estocásticas entre as distribuições estatísticas que modelam regiões pré-segmentadas nas imagens e as distribuições que modelam as amostras de treinamento, representantes das classes (SILVA, 2013). O desenvolvimento de distâncias entre distribuições de probabilidade está ligado à Teoria da Informação. Com base nos conhecimentos fixados por esta teoria, foram desenvolvidas várias medidas de dissimilaridade, com potencial aplicação em várias áreas do conhecimento. Dentre estas áreas, destacam-se o processamento digital de imagens e, especificamente, a classificação de imagens. Entre tais medidas encontra-se a família de divergências.

A divergência é uma medida da Teoria da Informação que encontra grande aplicação na diferenciação entre distribuições de variáveis aleatórias, podendo ser utilizada como uma medida de separabilidade entre leis de probabilidade (NASCIMENTO, 2012). Em Salicrú *et al.* (1994), é desenvolvida a família de divergências $h-\phi$ e suas distribuições estatísticas assintóticas, propiciando a utilização de intervalos de confiança e testes de hipóteses derivados dessas medidas.

Silva *et al.* (2011) desenvolveram uma ferramenta computacional para classificação de imagens de sensores remotos, tendo como base as distâncias estocásticas desenvolvidas a partir da metodologia proposta pela formalização da família de divergências $h-\phi$. O classificador por regiões supervisionado desenvolvido, denominado **PolClass**, recebe como dados de entrada a imagem a ser classificada, uma imagem segmentada e amostras de treinamento e de teste, retornando uma imagem classificada juntamente com um plano de informação com valores- p correspondentes às incertezas da classificação, que será denominado mapa de incertezas.

A técnica de classificação sugerida, denominada classificação multifontes, possui

algumas vantagens em relação as técnicas tradicionais. Primeiro, nesta metodologia as imagens não são substituídas uma vez que o processo de integração é aplicado ao resultado da classificação da imagem. Como o processo de integração dos dados ocorre em nível diferente daquele apresentado na fusão de dados, as características dos dados originais são mantidas.

A metodologia multifonte é fundamentada em conceitos estatísticos que permitem a avaliação da acurácia e dos erros cometidos na classificação. Tal característica permite a análise da confiabilidade dos resultados de classificação. Resultados satisfatórios foram obtidos com essa nova metodologia de integração de imagens (BRAGA *et al.*, 2015a; BRAGA *et al.*, 2015b).

Este trabalho está organizado em cinco seções. Na Seção 2, são descritos os fundamentos teóricos necessários para o entendimento das demais seções. O material utilizado e a metodologia proposta são expostos na Seção 3. Os resultados são delineados na Seção 4 e na Seção 5 são apresentadas as considerações finais.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados conceitos fundamentais para compreensão da metodologia proposta. Na primeira seção são exibidas as definições de distâncias estocásticas e estatísticas de teste de hipótese e na segunda seção é descrito o Classificador por regiões PolClass.

2.1 Testes de hipóteses com base na família de distâncias $h-\phi$

Sejam X e Y variáveis aleatórias definidas sobre um mesmo domínio Ω com distribuições de probabilidade caracterizadas pelas densidades $f_X(x;\theta_1)$ e $f_Y(x;\theta_2)$ em que θ_1 e θ_2 são vetores de parâmetros. De acordo com Salicrú *et al.* (1994) a divergência $h-\phi$ entre X e Y é expressa por

$$D_{\phi}^h(X, Y) = h \left(\int_{x \in \Omega} \phi \left(\frac{f_X(x; \theta_1)}{f_Y(x; \theta_2)} \right) f_Y(x; \theta_2) dx \right), \quad (1)$$

onde $\phi: (0, \infty) \rightarrow [0, \infty)$ é uma função convexa, $h: (0, \infty) \rightarrow [0, \infty)$ é uma função estritamente crescente com $h(0) = 0$ e $h'(x) > 0$ para $\forall x \in \Omega$ em que h' representa a derivada de primeira ordem de h . Na Tabela 1 é apresentada a seleção das

funções h e ϕ , as quais geram, entre outras, as distâncias de Kullback-Leibler e Bhattacharyya sendo a última utilizada neste trabalho.

Tabela 1: Distância tipo $(h-\phi)$ e funções h e ϕ relacionadas

Distância $(h-\phi)$	$h(y)$	$\phi(x)$
Kullback-Leibler	y	$x \log(x)$
Bhattacharyya	$-\log(-y+1),$ $0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$

As medidas de divergência frequentemente não satisfazem a desigualdade triangular e conseqüentemente não são consideradas métricas (NASCIMENTO, 2012). Como as medidas de divergência não satisfazem sempre a propriedade de simetria, estas não caracterizam necessariamente distâncias. Divergências simetrizadas são denominadas distâncias neste trabalho. Portanto, uma solução simples para obtenção de distâncias ($d_{\phi}^h(X, Y)$) a partir das divergências é calculando:

$$d_{\phi}^h(X, Y) = \frac{D_{\phi}^h(X, Y) + D_{\phi}^h(Y, X)}{2}. \quad (2)$$

Se X e Y possuem a mesma distribuição com parâmetros diferentes, é suficiente escrever $d_{\phi}^h(\theta_1, \theta_2)$. Ao fazê-lo, tem-se que $d_{\phi}^h(\theta_1, \theta_2) \geq 0$ onde $d_{\phi}^h(\theta_1, \theta_2) = 0$ se, e somente se, $\theta_1 = \theta_2$, isto é, as distribuições de X e Y são iguais. Portanto, a distância entre elas é nula.

Salicrú *et al.* (1994) apresentaram um meio para transformar distâncias em testes estatísticos com propriedades assintóticas conhecidas. Sejam $\hat{\theta}_1 = (\hat{\theta}_{11}, \dots, \hat{\theta}_{1M})$ e $\hat{\theta}_2 = (\hat{\theta}_{21}, \dots, \hat{\theta}_{2M})$, estimadores de máxima verosimilhança de θ_1 e θ_2 com M parâmetros baseados em amostras independentes de tamanhos m e n , respectivamente. Sob a hipótese nula $H_0: \theta_1 = \theta_2$ e a hipótese alternativa $H_1: \theta_1 \neq \theta_2$ obtém-se a seguinte estatística de teste de hipótese S_{ϕ}^h :

$$S_{\phi}^h(\hat{\theta}_1, \hat{\theta}_2) = \frac{2mn\nu}{m+n} d_{\phi}^h(\hat{\theta}_1, \hat{\theta}_2) \quad (3)$$

onde $\nu = 1/[h'(0) \phi''(1)]$ é uma constante que depende das funções h e ϕ , específicas para a

distância estocástica d_ϕ^h e h' e ϕ'' são as 1ª e 2ª derivadas de h e ϕ respectivamente. Obedecendo a condições específicas de regularidade, se $m, n \rightarrow \infty$ e $\theta_1 = \theta_2$ então

$$\frac{2mnv}{m+n} d_\phi^h(\hat{\theta}_1, \hat{\theta}_2) \xrightarrow{D} \chi_M^2 \quad (4)$$

em que \xrightarrow{D} denota convergência em distribuição e χ_M^2 é a distribuição Qui-quadrado com M graus de liberdade, onde M corresponde ao número de parâmetros em θ_j , $j \in \{1, 2\}$. Para valores suficientemente grandes de m e n , a hipótese nula ($H_0: \theta_1 = \theta_2$) é rejeitada ao nível de significância η se $Pr(\chi_M^2 > s) \leq \eta$ em que $s = S_\phi^h(\hat{\theta}_1, \hat{\theta}_2)$ (FRERY *et al.*, 2013).

2.2 O classificador por regiões *PolClass*

Na abordagem clássica, a atribuição de determinada classe a cada segmento se dá pela menor distância estocástica entre o modelo estatístico que representa o conjunto de pixels contidos no segmento em questão e o que representa o conjunto de pixels nas amostras de treinamento, para o caso da classificação supervisionada por regiões (SILVA, 2013). Nesta abordagem é, em geral, feita a suposição que os dados seguem uma distribuição Gaussiana multivariada.

Em Silva (2013) e Silva *et al.* (2011) é desenvolvido um classificador por regiões baseado em distâncias estocásticas. Este classificador possui vários diferenciais quando comparado à abordagem clássica, tais como: a) a atribuição dos pixels à uma dada classe é feita pela estatística de teste e não pela distância; b) um mapa de incertezas da classificação é gerado, através dos valores- p associados a esta estatística de teste; c) o classificador foi desenvolvido para tratar imagens de radar e, portanto, é possível utilizar outras funções de densidade de probabilidade além da Gaussiana multivariada, como, por exemplo, a função Wishart, utilizada para modelar a matriz de covariância de dados de radar de abertura sintética (*Synthetic Aperture Radar* - SAR) polarimétricos. A seguir é feita uma breve descrição deste classificador.

Suponha uma imagem com r segmentos disjuntos C_1, \dots, C_r , e que as variáveis aleatórias associadas aos pixels pertencentes a cada segmento possuam uma função densidade de probabilidade $f(x; \square_i)$, com $1 \leq i \leq r$, onde \square_i é o seu vetor de parâmetros. Suponha também que para cada segmento C_i , com $1 \leq i \leq r$, os vetores de parâmetros θ_i sejam estimados pelo método de máxima verossimilhança, denominado $\hat{\theta}_i$. Na classificação, que ocorre de forma supervisionada, o usuário seleciona k classes de interesse, com as quais se estimam os parâmetros $\hat{\theta}_\ell$, $1 \leq \ell \leq k$. São computadas $r \times k$ estatísticas de teste para a verificação da hipótese nula $H_0: \hat{\theta}_i = \hat{\theta}_\ell$ para cada segmento $1 \leq i \leq r$ e cada classe $1 \leq \ell \leq k$. A classificação com base na mínima estatística de teste consiste em atribuir ao segmento C_i a t -ésima classe se

$$S_\phi^h(\hat{\theta}_i, \hat{\theta}_t) < S_\phi^h(\hat{\theta}_i, \hat{\theta}_\ell) \quad (5)$$

$\forall t \neq \ell$. Uma vez que o segmento C_i foi rotulado com a classe t , o valor- p associado ao teste de hipóteses é calculado por

$$p_{i,t} = Pr(\chi_M^2 > s_\phi^h(\hat{\theta}_i, \hat{\theta}_t)), \quad (6)$$

em que M corresponde ao número de parâmetros em θ_i para algum i . Quando se supõe que os dados possuem distribuição Gaussiana multivariada com q variáveis tem-se que $M = q(q+3)/2$. A partir da obtenção dos valores- p para cada segmento classificado, é gerado um mapa, representativo da confiabilidade da classificação obtida (SILVA, 2013).

O classificador desenvolvido dispõe de três módulos: (1) Imagens Polarimétricas, (2) Par de Imagens SAR em intensidade e (3) Imagens ópticas e SAR multivariadas em amplitude. Em cada um destes módulos é utilizada a modelagem estatística mais adequada ao tipo de dado. Na Tabela 2 pode-se observar os tipos de imagens, as distribuições e as distâncias estocásticas disponíveis em cada módulo do classificador *PolClass*.

Tabela 2: Módulo do Classificador Polarimétrico por Regiões *PolClass*

Módulo	Modelagem estatística (Distribuição)	Distância Estocástica	Solução
Imagem polarimétrica	Wishart complexa escalonada	Bhattacharyya Kullback-Leibler Hellinger Rényi Qui-quadrado	Análítica
Par de imagem SAR em intensidade	Par de intensidades	Bhattacharyya Triangular	Numérica
Imagens ópticas e SAR multivariadas em Amplitude	Gaussiana	Bhattacharyya Kullback-Leibler	Análítica

3. MATERIAIS E MÉTODOS

Neste item é apresentada a área de estudo, os dados utilizados, assim como a metodologia desenvolvida para este trabalho.

3.1 Área de estudo

A área em estudo refere-se à parte da Floresta Nacional do Tapajós e arredores. Trata-se de uma importante unidade de conservação da natureza localizada na Amazônia brasileira às margens do Rio Tapajós, na região do estado do Pará. Na Figura 1 ilustra-se a área em estudo acompanhada de uma imagem ALOS 1/ PALSAR 1 em composição colorida HH(R) HV(G) HH(B), adquirida em 21 de junho de 2010.

Segundo o Instituto Brasileiro do meio ambiente e dos recursos naturais renováveis (IBAMA), a ocupação desta região iniciou-se com a assinatura do Decreto-Lei 1.106 de 16 de junho de 1970. Em virtude da ocupação, verifica-se a presença de mosaicos de vegetação secundária em vários níveis de desenvolvimento, pastagens e áreas cultivadas inseridas em uma matriz de floresta primária (ARAGÃO, 2004).

No exterior da Flona, são encontradas áreas mecanizadas para a produção de grãos, como soja, arroz, milho e sorgo. Existem relatos de atividades de extração de madeira e de minério, caça e pesca nos rios Tapajós e Cupari (ESCADA *et al.*, 2009). Outro fato que chama atenção é a ocorrência de incêndios, causados principalmente pelo uso inadequado do fogo para manejar pastagens e preparar áreas para o plantio (IBAMA, 2014).

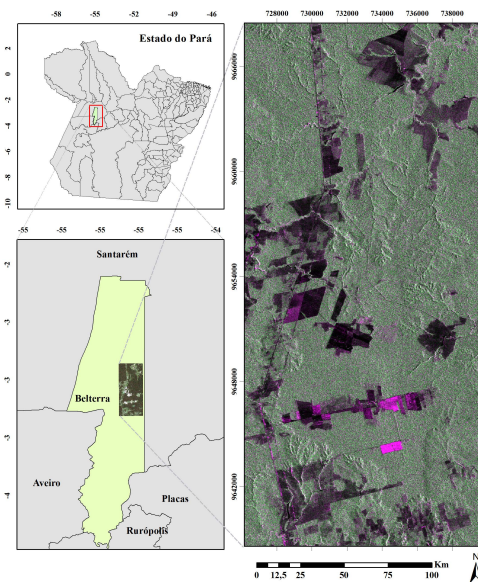


Fig.1 - Localização da área de estudo e um recorte da imagem ALOS 1/PALSAR 1 de 21 de junho de 2010 em composição colorida HH(R) HV(G) HH(B).

3.2 Dados

Os dados selecionados para exemplificar o procedimento de classificação multifonte proposto contemplam duas imagens, uma óptica e uma de micro-ondas. Estas imagens são ilustradas na Figura 2.




Fig.2 - Imagens da área de estudo a) LANDSAT5/TM de 29 de junho de 2010 em composição colorida 5(R) 4(G) 3(B) e b) ALOS 1/PALSAR 1 de 21 de junho de 2010 em composição colorida HH(R) HV(G) HH(B).

A imagem óptica é oriunda do sensor *Thematic Mapper* (TM) do satélite LANDSAT5, enquanto a de micro-ondas é proveniente do sensor *Phase Array L-Band Synthetic Aperture Radar 1* (PALSAR 1) do satélite *Advanced Land Observing System 1* (ALOS 1) nas polarizações HH e HV com número estimado de *looks* igual a 5. A imagem LANDSAT5/TM de órbita/ponto 227/62 datada de 29 de junho de 2010, foi obtida do catálogo do INPE (INPE, 2013a) e será denominada de imagem TM. Suas principais características são apresentadas na Tabela 3.

A imagem ALOS 1/PALSAR 1 data de 21 de junho de 2010, escolhida por ser a data mais próxima onde havia imagens dos dois sensores disponíveis e em épocas onde se espera que as condições climáticas sejam semelhantes. Esta imagem será chamada apenas de imagem PALSAR e suas características são descritas na Tabela 4.

Tabela 3: descrição das características da imagem TM

Características	Imagem
Resolução espacial	30 m *
Resolução radiométrica	8 bits
Resolução espectral	0,45 a 0,52 μm 0,52 a 0,60 μm 0,63 a 0,69 μm 0,76 a 0,90 μm 1,55 a 1,75 μm 10,4 a 12,5 μm 2,08 a 2,35 μm
Resolução temporal	16 dias
Faixa imageada	185 km

* a banda 6 possui resolução espacial de 120 m (INPE, 2013a).

Tabela 4: descrição das características da imagem PALSAR

Características	Imagem
Ângulo de incidência no centro da cena	38,7°
Nível de processamento	1.1
Modo de operação	<i>Fine Beam Dual</i> (FBD)
Polarizações	HH e HV
Órbita	Ascendente
Número de visadas	1
Resolução espacial	≈ 10 m em range e ≈ 4,5 m em azimuth
Resolução radiométrica	32 bits
Espaçamento entre pixels	9,36 m em range e 3,19 m em azimuth
Comprimento de onda	≈ 23 cm (Banda L)

Além das imagens óptica e de micro-ondas, compondo os dados de entrada encontram-se uma imagem segmentada contendo 17568 pixels, uma vez que o classificador adotado é supervisionado, e amostras de treinamento e teste. Os dados aqui referidos coincidem com aqueles empregados na dissertação de REIS (2014). Nesta dissertação é possível obter maiores detalhes acerca de todo o pré-processamento cuja descrição é dada brevemente na subseção 3.3.1 da metodologia.

3.3 Metodologia

A metodologia está dividida em quatro etapas. A primeira etapa refere-se ao pré-processamento dos dados. Essa etapa se subdivide em pré-processamento das $w = 2$ imagens oriundas de fontes distintas (óptica e de micro-ondas) e unificação das imagens segmentadas correspondentes. No estágio seguinte são definidas as classes em estudo e é apresentado o processo de coleta das amostras de treinamento e teste. Na terceira etapa são delineados os passos para construção das classificações multifontes. Essas classificações correspondem aos resultados da combinação das classificações das imagens. Por fim, na última etapa, são exibidos os Cenários de classificação (classificação e mapa de incertezas) construídos por intermédio da metodologia multifonte.

3.3.1 Pré-processamento

O pré-processamento das imagens é fundamental para obtenção de bons resultados de classificação. Nesta seção é apresentada uma breve descrição dos estágios relativos ao pré-processamento dos dados.

Como a imagem TM foi obtida do catálogo do INPE, não foi necessário aplicar as correções geométricas e radiométricas pois o produto TM padrão concedido pelo INPE possui essas correções de sistema. Além disto, ele é disponibilizado no sistema de projeção UTM (*Universal Transverse Mercator*) e datum WGS84 (*World Geodetic System 1984*) (INPE, 2013b).

A correção atmosférica não foi aplicada à imagem TM, pois o trabalho aborda um método de classificação supervisionada de imagens. Neste caso, uma correção atmosférica dos dados TM não é necessária, pois não há comparação entre valores digitais das imagens envolvidas

(imagens óptica e de micro-ondas) no processo de classificação ora proposto (SONG *et al.*, 2001).

A imagem PALSAR foi projetada para o sistema UTM WGS84, zona 21 sul e os pixels foram reamostrados para 15 por 15 m. A geocodificação foi realizada utilizando-se o *software* ASF *MapReady* versão 3.0. Após este processo, a imagem, originalmente em valores complexos e em *slant range*, foi convertida para amplitude e formato *ground range*.

As imagens TM e PALSAR foram ortorretificados no *software* PCI 13.0, com o modelo *rational function* (*Rational Function Model-RFM*) e os dados do SRTM 4 como Modelo Digital de Elevação (MDE). O RFM utiliza pontos de controle para construir correlações entre os pixels de uma imagem e sua localização no terreno. Esses pontos foram coletados utilizando como base uma imagem PALSAR FBD (*Fine Beam Dual*) 1.5 de 30 de abril de 2008 disponibilizada e ortorretificada pelo IBGE. Essa ortorretificação ocorreu sem a utilização de pontos de controle por meio do MDE SRTM, com resolução nominal de 20 m e espaçamento entre pixels de 12,5 m, com uma acurácia planimétrica esperada de 31 m.

Visando melhores resultados de classificação, atributos de textura foram extraídos da imagem SAR. Desta forma, além da bandas HH e HV, outras três bandas compõem a imagem de micro-ondas a ser classificada: banda relativa à imagem de dissimilaridade da banda HH da imagem PALSAR; banda relativa à imagem de homogeneidade da banda HH da imagem PALSAR e banda relativa à imagem de média da banda HV da imagem PALSAR.

Para classificação da imagem TM foram utilizadas seis bandas, bandas 1 à 5 e banda 7. Feitas as correções necessárias e definidas as bandas a serem utilizadas, as imagens TM e PALSAR foram registradas entre si gerando imagens de 916 por 1996 pixels com resolução espacial de 15 m, sendo a segunda utilizada como referência.

No processo de classificação multifontes adotado, a imagem segmentada utilizada deve ser única para as w imagens provenientes das w fontes distintas a serem classificadas. Desta forma, foram geradas individualmente a imagem segmentada para cada uma das w imagens e posteriormente, fez-se a combinação (através de operações lógicas)

destas imagens gerando uma única imagem segmentada.

Para a segmentação da imagem PALSAR utilizou-se o *MultiSeg* (SOUZA jr, 2005). O *MultiSeg* é um segmentador de imagens de radar e ópticas que utiliza técnicas de agrupamento e crescimento de regiões, detecção de bordas, teste de homogeneidade e teste de área mínima e forma integrada a uma estrutura de compressão piramidal (REIS, 2014). Neste segmentador, pode-se trabalhar com uma ou mais bandas de uma imagem. O segmentador trabalha com dois modelos para representação de dados: manchas e texturas. O primeiro modelo baseia-se na hipótese de que a imagem é formada por regiões uniformes, enquanto o modelo de textura considera que a imagem pode ser formada por regiões com textura induzida por ruído. Nestes modelos, alguns parâmetros são essenciais, tais como, similaridade, nível de confiança e área mínima. O parâmetro de similaridade é fornecido pelo usuário em decibéis e define o limiar de similaridade para os testes de crescimento e agrupamento de regiões. O nível de confiança é uma medida de probabilidade associada a um intervalo de tolerância estatístico ou intervalo de confiança. Este valor reflete a probabilidade de determinado intervalo de confiança, calculado a partir de um valor amostral, conter o verdadeiro valor da população.

A área mínima indica o tamanho mínimo em pixels das regiões no último nível de segmentação. Este parâmetro evita o aparecimento de regiões muito pequenas na segmentação resultante. Para a segmentação da imagem de micro-ondas deste trabalho utilizaram-se somente as bandas originais da imagem PALSAR, HH e HV adotou-se o modelo de manchas com similaridade de 1,0 db, área mínima de 20 pixels e nível de confiabilidade de 95%.

Em um conjunto de dados, a seleção de atributos ocorre ao selecionar-se os dados que reduzem a dimensionalidade do espaço de atributos preservando a informação a respeito da discriminação das classes. Esse procedimento resulta na triagem dos dados em que observa-se maior separabilidade entre as classes e uma variância pequena em uma mesma classe.

Entre as mais conhecidas medidas de separabilidade entre classes em um vetor de atributos, pode-se citar a distância de *Jeffries-*

Matusita (JM). Essa distância varia entre 0 (quando não há separabilidade no par de classes investigado) e $\sqrt{2}$ (quando o par de dados são totalmente separáveis). Assim, quanto maior a distância entre duas classes, maior é a separabilidade das mesmas.

A utilização desta distância ocorre da seguinte maneira, computam-se todas as combinações entre bandas possíveis, calcula-se para cada uma destas combinações a distância JM mínima (enfatizando-se as classes mais difíceis de se separar) entre todos os pares de classes e seleciona-se a combinação que maximiza a distância JM mínima.

Considerando-se todas as combinações possíveis entre as seis bandas da imagem TM utilizada, foi selecionada a combinação que maximizou a distância JM mínima. Sendo assim, para fins de segmentação utilizaram-se as bandas 2, 4 e 5 da imagem TM. No processo, essas bandas foram normalizadas para média = 127 e desvio padrão = 42 e convertidas para byte para otimizar a segmentação e garantir peso igual para todas as bandas em diferentes *softwares*.

Para a segmentação da imagem TM utilizou-se a rotina para segmentação *Multiresolution Segmentation* (E-Cognition). No procedimento de segmentação, esta rotina minimiza localmente a heterogeneidade interna de cada segmento, podendo ser executada a partir de pixels em uma imagem ou de uma segmentação prévia. Durante o processo, a imagem é particionada em regiões homogêneas, podendo ser influenciada por parâmetros de escala, tonalidade e forma. O parâmetro de escala influencia a heterogeneidade dos pixels, definindo o tamanho dos objetos; a tonalidade equilibra a homogeneidade das cores dos segmentos com a homogeneidade da figura; o parâmetro de forma promove o equilíbrio entre a suavidade da borda de um segmento e a compacidade, estabilizando os critérios de homogeneidade dos objetos primários (LUZ *et al.*, 2010). A tonalidade e a forma são parâmetros complementares assim como a suavidade e compacidade. Para esta segmentação da imagem TM utilizou-se os valores 0,3 para os parâmetros de forma e de compacidade e 30 para o parâmetro de escala.

As imagens segmentadas provenientes dos dados SAR e óptico foram combinadas, por

meio de operações lógicas, a fim de se gerar uma única imagem segmentada. Neste procedimento, as regiões contendo menos que 20 pixels foram agrupadas às regiões fronteiriças e maiores. Após o processo de unificação, gerou-se uma única imagem segmentada contendo 17568 regiões.

3.3.2 Amostras das classes em estudo

A partir de vários trabalhos de mapeamento/classificação já elaborados nesta área de estudo, como por exemplo, Pereira (2012), Pereira *et al.* (2013), Guerra (2009), Aboud Neta (2009), Reis (2014) entre outros, bem como dos trabalhos de campo realizados é possível definir diversas classes de uso e cobertura da terra presentes nesta região. Uma descrição simplificada pode ser encontrada em Reis (2014) e é dada por:






- a) Floresta Primária: floresta em que a ação humana não provocou ações significativas em suas características originais de estrutura e espécies;
- b) Floresta Degradada: floresta degradada por atividades de fogo ou por desmatamento seletivo, de forma que suas características originais tenham sido alteradas, mas ainda possuam porte florestal;
- c) Vegetação Secundária Avançada: florestas secundárias em avançado estágio de desenvolvimento, com predomínio de árvores geralmente entre 13 e 17 m, mas ocorrência de árvores emergentes e, em menor grau, arbustos e herbáceas;
- d) Vegetação Secundária Intermediária: áreas com presença de vegetação secundária com poucas espécies herbáceas e predominância de árvores de pequeno porte e arbustos;
- e) Vegetação Secundária Inicial: áreas de vegetação secundária com predominância de herbáceas e arbustos;
- f) Pasto Limpo: áreas com vegetação típica de pastagens, com predomínio de herbáceas;
- g) Pasto Sujo: áreas com vegetação típica de pastagens, com presença de espécies arbustivas, árvores e espécies invasoras;
- h) Área Cultivada: culturas de grãos;
- i) Área em Pousio: áreas agrícolas em pousio, cobertas por palha ou vegetação esparsa; e
- j) Solo Exposto: áreas predominantemente de solo sem nenhum tipo de cobertura vegetal.

Para aplicação da metodologia, adotaram-se cinco classes que são resultados do agrupamento

das classes utilizadas por Reis (2014), são estas: Floresta Primária (FP), Regeneração (RG), Solo Exposto (SE), Pasto (PA) e Soja (SO). A classe Regeneração inclui Floresta Degradada e Vegetações Secundárias (inicial, intermediária e avançada) enquanto a classe Pasto engloba Pasto limpo, Pasto sujo e Pousio.

As imagens TM, PALSAR e a imagem segmentada empregadas neste trabalho foram as mesmas utilizadas no trabalho de Reis (2014). Os dados foram disponibilizados com todos os passos de pré-processamento finalizados. As amostras de treinamento (para treinar o classificador) e amostras de teste (para avaliar o classificador) também foram obtidas por Reis (2014), por meio de dados de campos realizados em 2009 e 2010, chave de interpretação, série histórica de imagens LANDSAT5/TM, dados do projeto Terra Class e algumas imagens de 2008 presentes na biblioteca digital de fotos da Coordenação Geral de Observação da Terra do INPE. A Tabela 5 contém o número de amostras coletadas para cada uma das cinco classes e na Figura 3 é possível ver uma ilustração de cada uma destas amostras na região em estudo.

Tabela 5: Número de amostras por classe

Classes		Amostras de treinamento	Amostras de teste
	cor	Pixels	Pixels
Floresta Primária		7307	6575
Regeneração		17633	20606
Pasto		11296	7336
Soja		2099	2187
Solo Exposto		4769	4467

3.3.3 Classificação multifonte

O fluxograma representado na Figura 4 apresenta a metodologia proposta aplicada à combinação das imagens TM e PALSAR. O primeiro passo para execução da técnica é obter a classificação de cada uma das imagens. Neste caso, utilizou-se o classificador *PolClass*. No trabalho em questão, para fins de avaliação da metodologia, foram utilizadas seis bandas (1 à 5 e 7) da imagem TM (óptica) e cinco bandas (polarizações HH e HV mais três atributos extraídos destas polarizações) da imagem PALSAR (micro-ondas). Para classificação das imagens utilizou-se o módulo para imagens ópticas e SAR em amplitude multivariada com modelagem estatística



Fig. 3 - Amostras de treinamento (polígonos cheios) e de teste (polígonos hachurados) sobrepostas à imagem TM nas bandas 1(R), 2(G) e 3(B).

Gaussiana e distância estocástica de Bhattacharyya disponíveis no *PolClass*. Utilizou-se também uma imagem segmentada unificada contendo 17568 regiões. A partir dos *k*-mapas fornecidos no processo de classificação de cada uma das imagens foram construídos cinco Cenários de classificação (classificação e mapa de incertezas) distintos, sendo os três últimos (classificações multifontes) construídos por intermédio das classificações individuais (classificações monofontes).

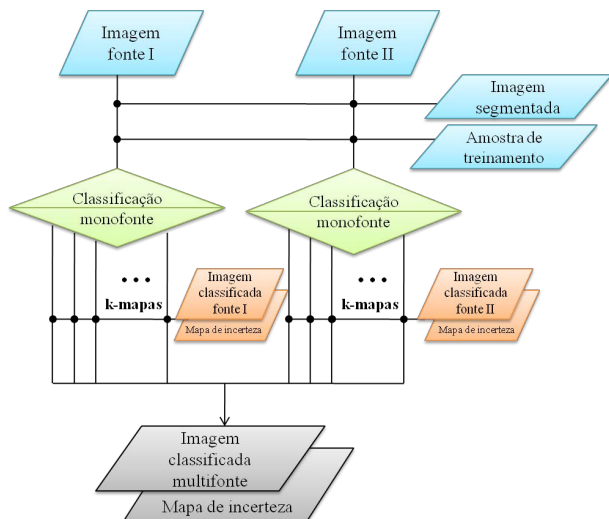


Fig. 4 - Estrutura metodológica.

No processo de classificação do **PolClass**, após a entrada dos dados, são calculados valores de distância, estatística e valor- p para cada região da imagem segmentada em relação a cada uma das amostras de treinamento representantes das classes. Por intermédio destes valores, são gerados k -mapas de incertezas relativos as k classes em estudo. No classificador, adota-se como classificação final, o plano de informação em que cada classe é definida por intermédio do máximo valor- p , ou mínima estatística s em relação aos k -mapas de incertezas calculados.

Além das classificações das imagens TM e PALSAR, diante de cada um dos k -mapas gerados, foram criados novos Cenários considerando-se as informações relativas às menores incertezas dentre os resultados calculados.

3.3.4 Cenários de classificação

A princípio, os Cenários seriam originados com base nos valores- p de cada classificação individual, uma vez que estes correspondem à incerteza com que cada classificação foi realizada, no entanto, notou-se que uma porcentagem grande de valores- p foi próxima de zero, tornando-se inviável sua utilização no trabalho. Todavia, tanto o valor- p quanto à estatística s são indicativos do grau de incerteza (quanto menor o valor- p , maior a incerteza e quanto maior a estatística s , maior a incerteza). Portanto, decidiu-se por calcular o grau de incerteza da classificação por meio da estatística s .

É importante citar o fato de que uma normalização da estatística s , através da

subtração do valor s crítico (s_c) foi necessária uma vez que a mesma não se trata de uma probabilidade. Após tal normalização, embora essa nova estatística normalizada seja um número no intervalo $[0,1]$, o parâmetro continua não sendo uma probabilidade, mas passa a ter uma interpretação de possibilidade. A origem dos Cenários de classificação seguiu a metodologia apresentada a seguir.

Seja o conjunto A formado por Z diferentes imagens as quais se deseja classificar em k classes. Suponha também uma única segmentação dessas imagens em r regiões. Para cada imagem z , $z \in \{1,2,\dots,Z\}$ e a cada região i , $i \in \{1,2,\dots,r\}$ pode ser calculado um vetor de atributos $V_{il}^z = (p_{il}^z, s_{il}^z, d_{il}^z)$ $l \in \{1,2,\dots,k\}$. Os atributos p_{il}^z (probabilidade) e s_{il}^z (estatística normalizada) indicam a incerteza da possível atribuição da classe l à região i na imagem z , enquanto d_{il}^z (distância estocástica) representa a distância estocástica entre a classe l à região i .

Diferentes classificações e mapas de incertezas associados à imagem z podem ser gerados a partir de funções dos elementos dos vetores de atributos V_{il}^z . Cada uma dessas classificações juntamente com seus mapas de incertezas é denominada aqui Cenário de classificação ou simplesmente Cenário.

Neste trabalho, para exemplificar a metodologia proposta, o conjunto A é formado pelas imagens TM (T) e PALSAR (R) ($A = \{T, R\}$) as quais foram classificadas nas cinco classes (FP, RG, PA, SO e SE) levando-se em conta as 17568 regiões da imagem segmentada. V_{il}^T e V_{il}^R $i \in \{1,2,\dots,17568\}$, $l \in \{1,2,\dots,5\}$ representam os vetores de atributos para estas imagens, como descrito acima. Os seguintes Cenários foram construídos:

3.3.4.1 Cenário I

Trata-se da classificação da imagem TM e de seu respectivo mapa de incerteza (classificação monofonte). Para cada região i é atribuída à classe l que possui menor s_{il}^T , $l \in \{1,2,\dots,5\}$. O mapa de incertezas é formado pelas incertezas s_i^T associadas às classificações das regiões i na classe l .

3.3.4.2 Cenário II

Equivale à classificação da imagem PALSAR e de seu respectivo mapa de incerteza (classificação monofonte). Para cada região i é atribuída à classe v que possui menor $s_{i\ell}^R$, $\ell \in \{1, 2, \dots, 5\}$. O mapa de incertezas é formado pelas incertezas s_v^R associadas às classificações das regiões i na classe v .

3.3.4.3 Cenário III

Este corresponde à classificação que utiliza informações dos Cenários I e II (classificação multifonte). Neste Cenário, para cada região i é atribuída a classe u que possui menor valor de estatística entre $s_{i\ell}^T$ e $s_{i\ell}^R$, $i \in \{1, 2, \dots, 5\}$. O mapa de incertezas é formado pelas incertezas $s_{iu}^{TR} = \min\{s_{i\ell}^T, s_{i\ell}^R\}$ associadas às classificações das regiões i na classe u .

3.3.4.4 Cenário IV

O cenário representa a classificação que utiliza informações das classificações das imagens TM e PALSAR (classificação multifonte). Para tal, são calculados para cada região i os valores de $s_{i\ell}^{TR} = s_{i\ell}^T \times s_{i\ell}^R$ para todas as ℓ classes, onde $\ell \in \{1, 2, \dots, k\}$ e \times indica a operação de multiplicação. Neste Cenário, para cada região i é atribuída a classe e que possui menor $s_{i\ell}^{TR}$. O mapa de incertezas é formado pelas incertezas s_{ie}^{TR} associadas às classificações das regiões i na classe e .

3.3.4.5 Cenário V

Este também corresponde à classificação que utiliza informações das classificações das imagens TM e PALSAR (classificação multifonte). Este último cenário inclui um tipo de lógica que tem por objetivo modelar modos de raciocínio aproximados ao invés de precisos. Neste caso, as proposições podem ter valores intermediários entre verdadeiro e falso e a veracidade destas é uma função que pode assumir qualquer valor entre zero (absolutamente falso) e um (absolutamente verdadeiro). Essa lógica é conhecida como lógica *Fuzzy* (ou difusa) e visa modelar modos de raciocínio imprecisos, tendo os casos precisos como situações limites.

O objetivo da utilização deste tipo de lógica na classificação de imagens é mostrar que uma tomada de decisão pela classificação mais

representativa da realidade pode ser relativa. Isto porque a imagem de uma determinada região pode não possuir necessariamente uma classificação exata. Desta maneira, as classes neste Cenário não são formadas apenas pelas cinco classes (FP, RG, PA, SO e SE) apresentadas até o momento, mas por combinações destas.

Exemplificando, associando-se números de 1 a 5 às cinco classes em estudo seguindo-se a ordem das classes mencionadas anteriormente. Isto é, à classe FP associa-se 1 e à classe SE associa-se 5. Se para a região i o Cenário I associou a classe Pasto (3) e, por outro lado o Cenário II associou a mesma região i a classe Soja (4), neste quinto Cenário, a região i será associada a uma nova classe denominada PA_SO e sua respectiva incerteza será resultado do produto das incertezas s_{i3}^T e s_{i4}^R .

Ao proceder deste modo, pode-se, então gerar quinze classes fuzzy, denominadas por PA_PA, PA_SO, PA_RG, PA_FP, PA_SE, SO_SO, SO_RG, SO_FP, SO_SE, RG_RG, RG_FP, RG_SE, FP_FP, FP_SE e SE_SE. O mapa de incertezas é formado pelas incertezas $s_{i\sigma}^T \times s_{i\xi}^R$ associadas às classificações das regiões i nas classes σ e ξ onde \times representa a operação de multiplicação.

4. RESULTADOS

O primeiro Cenário de classificação é apresentado na Figura 5. Este Cenário está relacionado à classificação da imagem TM. No mapa de incertezas, a escala de cores é interpretada da seguinte maneira, quanto mais próximo do azul escuro, menor a incerteza relacionada à classificação.

No geral, as incertezas apresentadas não são comparáveis uma vez que os valores não foram normalizados entre si. Quando normalizados entre si, alguns mapas não apresentavam variação de cores devido aos baixos valores de incertezas, tendendo assim para uma imagem azul homogênea em todas as regiões. Optou-se então, por apresentar nos mapas de incertezas os valores de mínimos e máximos relativos a cada uma das classificações de forma a facilitar a visualização da variação das incertezas por classe.

Para validação da classificação, por meio da amostra de teste, computou-se a matriz de confusão. Essa matriz expressa a concordância entre a imagem classificada e o conjunto de




Fig. 5 - Imagem classificada e seu mapa de incertezas correspondentes ao Cenário I.

amostras de referência (amostra de teste). Erros de omissão (exclusão) e de comissão (inclusão) de cada classe são calculados a partir dessa matriz. Os valores da diagonal principal da matriz quadrada correspondem ao número de pixels que foram corretamente classificados segundo um conjunto de dados que compõem a verdade de campo. A matriz de confusão para o Cenário de classificação I é apresentada na Figura 6.

Observando o resultado da classificação, seu mapa de incertezas e sua matriz de confusão, percebe-se que a incerteza foi menor para duas classes, Floresta e Regeneração. Estas classes foram bem classificadas neste Cenário de classificação.

Todos os pixels da amostra de teste da classe Floresta foram classificados corretamente. Desta maneira, para esta classe, não houve erros de omissão ou comissão. Para a classe Solo Exposto, por exemplo, a exatidão foi de 89,88% e alguns erros foram cometidos. Parte das amostras pertencentes a esta classe (10,12%) foram classificadas como pertencentes à classe Pasto caracterizando erro de omissão. Por outro lado, parte dos pixels relativa à classe Pasto foi classificada como pertencente à classe Soja (3,87%), caracterizando um erro de comissão para esta classe.

Embora a acurácia referente à classe Soja

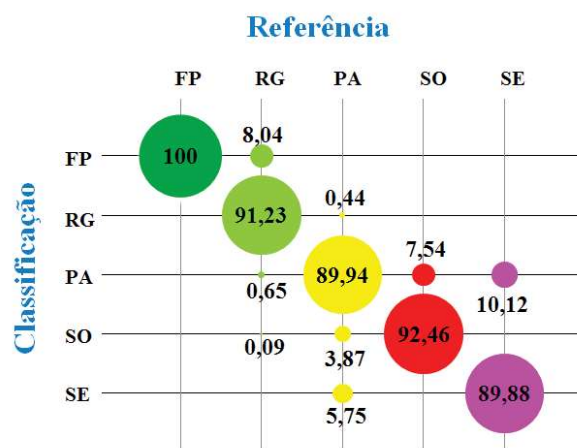


Fig. 6 - Matriz de confusão relativa ao Cenário I.

tenha apresentado valor inferior somente em comparação à classe Floresta, as incertezas relacionadas à classe Soja estão entre as maiores. Além desta classe, altos valores de incertezas também estão associados às classes Pasto e Solo Exposto.

O Cenário II de classificação correspondente à classificação da imagem PALSAR e seu mapa de incertezas são apresentados na Figura 7. Sua matriz de confusão é exibida na Figura 8.

A matriz de confusão para o Cenário de classificação II apresentou exatidão inferior em relação ao Cenário de classificação I na maior parte das classes. Contudo, a classe Solo Exposto foi mais bem classificada para este Cenário com exatidão de 99,96% além de apresentar o menor erro de omissão em relação ao Cenário anterior.

O Cenário de classificação III é apresentado na Figura 9. Nota-se por meio de sua matriz de confusão, representada na Figura 10, um equilíbrio em relação aos resultados dos Cenários anteriores. Os erros de comissão neste Cenário possuem valores intermediários entre os erros expostos pelos Cenários I e II exceto para a classe Soja, na qual o erro de comissão foi nulo. No caso dos erros de omissão, os valores também foram intermediários àqueles apresentados nos Cenários anteriores, exceto para a classe Solo Exposto, cujo valor foi o menor entre aqueles exibidos. Vale ressaltar que o erro de comissão para a classe regeneração e o erro de omissão para a classe Floresta, embora sejam valores intermediários, foram baixos, próximos àqueles apresentados no primeiro Cenário.




Fig. 7 - Imagem classificada e seu mapa de incertezas correspondentes ao Cenário II.




Fig. 8 - Matriz de confusão relativa ao Cenário II.




Fig. 9 - Imagem classificada e seu mapa de incertezas correspondentes ao Cenário III.

Quanto à acurácia da classificação, seus valores foram superiores aqueles expostos pelo Cenário II em grande parte das classes e embora tenha sido inferior para a classe Solo Exposto, seu valor foi bem próximo aquele apresentado pelo segundo Cenário. Em relação ao Cenário de classificação I, a acurácia foi maior para a classe Solo Exposto, próxima para a classe Floresta e inferior para as outras classes. De maneira geral, os resultados deste Cenário de classificação não superaram os resultados dos Cenários anteriores para nenhuma classe em específico.

O quarto Cenário de classificação é apresentado na Figura 11. Claramente, este Cenário apresentou baixos valores de incertezas e sua matriz de erros, representada na Figura 12, mostrou boa exatidão de classificação para todas as classes em estudo.

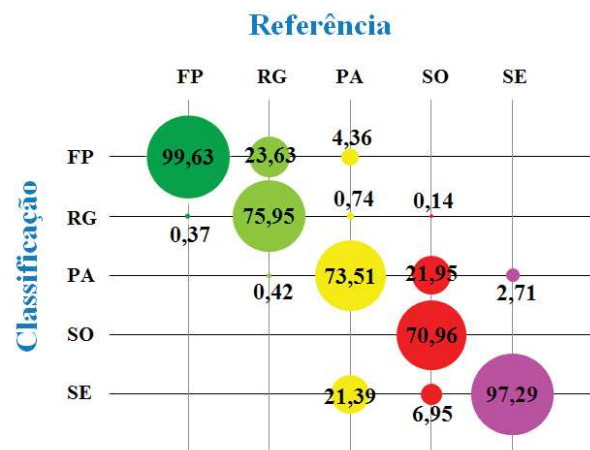


Fig. 10 - Matriz de confusão relativa ao Cenário III.




Fig. 11 - Imagem classificada e seu mapa de incertezas correspondentes ao Cenário IV.

Comparando-se o Cenário de classificação IV, e sua matriz de confusão com os resultados dos cenários anteriores, nota-se que os erros de comissão em relação às classes Pasto e Solo Exposto diminuíram. Em relação à classe Soja, o erro de comissão anulou-se.

Os erros de omissão das classes Pasto e Solo Exposto foram menores em relação ao Cenário I. Já o erro de omissão relativo à classe Floresta anulou-se assim como no primeiro Cenário de classificação.

Embora este Cenário tenha apresentado baixas incertezas, observa-se em sua matriz de confusão que sua maior exatidão foi apresentada em relação à classe Pasto, cujo valor foi superior aqueles exibidos pelos outros Cenários. O Cenário de classificação IV apresentou valor de acurácia igual ao Cenário I para a Classe Floresta e igual ao Cenário III para a classe solo Exposto, porém, os resultados apresentados pelo Cenário II superaram todos os outros na identificação da classe Solo Exposto. Desta forma, em relação aos outros Cenários de classificação, o Cenário atual apresentou maior eficiência na classificação da classe Pasto.




Fig. 12 - Matriz de confusão relativa ao Cenário IV.

A Tabela 6 contém informações quanto aos erros de comissão e omissão dos quatro cenários apresentados. Na Tabela 7 são exibidos o coeficiente de concordância *kappa*, sua variância e a acurácia global para todos os Cenários de classificação até aqui discutidos. Os Cenários de classificação I e IV apresentaram os maiores valores de índices *kappa* e acurácia global. Por meio do teste *Z* de igualdade de *kappas* mostrou-

se que os valores *kappas* dos Cenários I e IV são estatisticamente iguais a um nível de significância de 95%. Os menores valores *kappas* referem-se ao Cenário II de classificação. Os valores exibidos pelo Cenário III de classificação são valores intermediários entre aqueles presentes nos Cenário I e II.

Na Figura 13 é apresentada a incerteza média por classe para os quatro primeiros Cenários. O Cenário de classificação IV possui as menores incertezas médias para todas as classes em estudo exceto para a classe Solo Exposto em que apresenta a maior incerteza média entre todos os outros Cenários.

O último Cenário de classificação construído com o auxílio da lógica *Fuzzy* é apresentado na Figura 14. Na mesma Figura pode-se ver a quantidade de pixel (em relação ao total de pixel na imagem) que foi classificada em cada uma das classes *Fuzzy*.

A classificação baseada na lógica *Fuzzy* exibiu resultados satisfatórios tornando-se assim um fator positivo na metodologia de classificação utilizada, pois permitiu uma classificação em classes mistas com baixos valores de incerteza. A matriz de confusão do Cenário de classificação V não pôde ser gerada como nos casos anteriores uma vez que nas classes *Fuzzy*, aparecem classes que não existem nas amostras de testes das imagens em questão. Ainda assim, conhecendo-se a verdade de campo pode-se estimar o quanto de acertos tal Cenário apresentou em relação às classes estudadas. Neste caso, se uma quantidade de pixel foi classificada como PA_SO e pertence à classe Pasto, tal decisão é considerada válida. Assim como o seria se outra quantidade de pixel fosse classificada como PA_SO e pertence à classe Soja. Utilizando-se esse raciocínio a Tabela 8 foi construída para análise do Cenário de classificação V. Na Tabela 8, o número total de pixels está relacionado aos pixels coletados para composição das amostras de teste.

Analisando a tabela percebe-se que neste Cenário, em meio aos 7336 pixels pertencentes à classe Pasto, 6824 pixels foram identificados corretamente, correspondendo a um percentual de acertos de 93,02%. Seguindo tal raciocínio tem-se que o percentual de acertos para a classe Soja foi 92,64%, 96,27% para a classe Regeneração e 100% para as classes Floresta e Solo Exposto.

Tabela 6: Acurácia (AC) e erros de comissão (C) e omissão (O) relativos aos quatro primeiros Cenários

%	Cenário I			Cenário II			Cenário III			Cenário IV		
Classe	AC	C	O	AC	C	O	AC	C	O	AC	C	O
FP	100,00	20,12	0,00	82,31	60,28	17,69	99,63	44,20	0,37	100,00	24,41	0,00
RG	91,23	0,17	8,77	60,86	8,87	39,14	75,95	0,51	24,25	88,86	2,03	11,14
PA	89,94	10,21	10,06	67,53	20,99	32,47	73,51	11,30	26,49	90,25	8,71	9,75
SO	92,46	12,99	7,54	41,56	14,00	58,44	70,96	0,00	29,04	83,86	0,00	16,14
SE	89,88	9,51	10,12	99,96	30,86	0,04	97,29	28,37	2,71	97,29	7,47	2,71

Tabela 7: Coeficiente *Kappa* e acurácia global relativos aos quatro primeiros Cenários

Classificação	<i>kappa</i>	Variância <i>kappa</i>	Acurácia Global
Cenário I	0,89	$2,93 \times 10^{-4}$	0,92
Cenário II	0,57	$6,16 \times 10^{-5}$	0,69
Cenário III	0,74	$1,09 \times 10^{-4}$	0,81
Cenário IV	0,88	$2,64 \times 10^{-4}$	0,92




Fig. 13 - Gráfico relativo às incertezas médias dos Cenários I à IV.

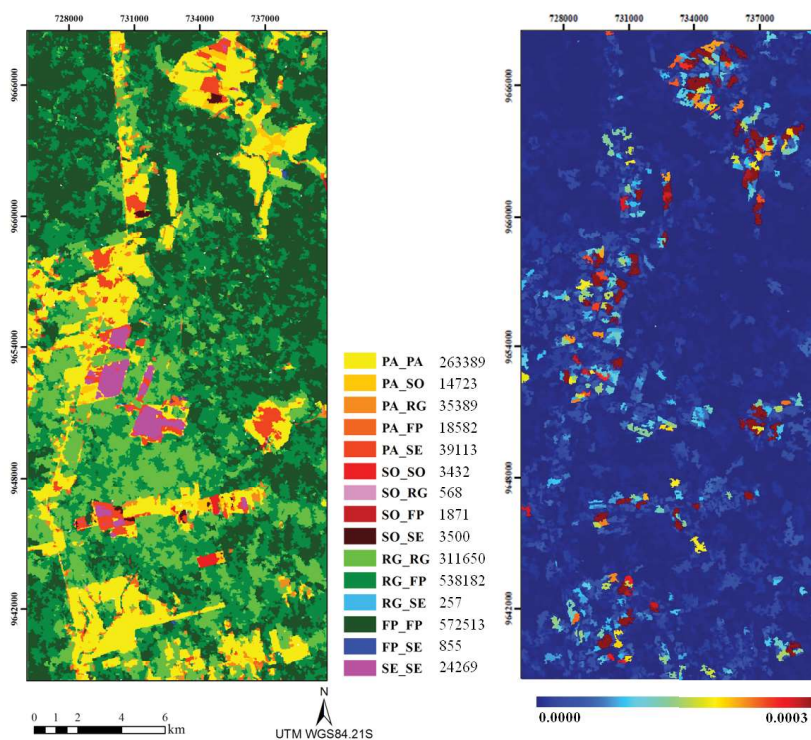


Fig. 14 - Imagem classificada e seu respectivo mapa de incertezas correspondentes ao Cenário V.

Tabela 8: Dados para análise da acurácia do Cenário V

Classes	Referência					
	FP	RG	PA	SO	SE	TOTAL
PA_PA	0	49	4728	158	0	4935
PA_SO	0	0	106	965	0	1071
PA_RG	0	146	28	3	0	177
PA_FP	0	84	343	0	0	427
PA_SE	0	0	1619	0	454	2073
SO_SO	0	0	0	905	0	905
SO_RG	0	18	0	0	0	18
SO_FP	0	0	0	0	0	0
SO_SE	0	0	326	156	0	482
RG_RG	0	11502	29	0	0	11531
RG_FP	1163	8171	0	0	0	9334
RG_SE	0	0	0	0	0	0
FP_FP	5412	636	0	0	0	6048
FP_SE	0	0	0	0	0	0
SE_SE	0	0	157	0	4013	4170
TOTAL	6575	20606	7336	2187	4467	41171

Na Figura 15 é apresentada a incerteza média para cada classe pertencente ao Cenário V. A equação 7 exhibe como essa incerteza média (IM) foi calculada. Nota-se que essa incerteza foi maior para a classe RG_SE. Uma possível explicação é o fato desta classe além de ser a que possui o menor número de pixels em relação a todas as outras classes *Fuzzy* (considerando-se o total de pixels da Cena), não possuir nenhum pixel nas amostras de teste para estimativa dos números de acertos da classe em questão.

$$IM_{\ell} = \frac{\sum_{cont=1}^r Num_i \times Inc_i}{\sum_{cont=1}^r Num_i}, \quad (7)$$

onde M_{ℓ} é a incerteza média calculada para a classe ℓ com $1 \leq \ell \leq k$, Num_i é o número de pixels presentes no segmento i , r é o número total de segmentos na imagem, Inc_i é a incerteza referente ao segmento i e $cont$ é o contador que varia de 1 à r .

Observando-se na Figura 16 a acurácia global de todos os resultados das classificações originadas, observa-se o Cenário *Fuzzy* em uma posição superior. Os Cenários I e IV possuem valores de acurácias próximos. O Cenário II, correspondente a classificação originada a partir de uma imagem SAR, possui a menor acurácia global em relação aos outros Cenários.




Fig. 15 - Gráfico da incerteza média para o cenário de classificação V.




Fig. 16 - Acurácia global dos cinco Cenários de classificação.

5. CONSIDERAÇÕES FINAIS

Observa-se na literatura que resultados de classificação de imagens obtidos por meio da integração de dados tem apresentado melhoras significativas em relação a resultados de classificação de imagens adquiridos individualmente. De forma geral, afirma-se que não existe um método de integração de dados excelente para toda e qualquer aplicação, porém, diversos estudos estão sendo desenvolvidos em busca de melhorias nas técnicas já existentes além da busca por novas técnicas de integração.

A técnica de classificação multifonte proposta possui algumas vantagens em relação as técnicas tradicionais. Primeiro, nesta metodologia as imagens não são substituídas uma vez que o processo de integração é aplicado ao resultado da classificação da imagem. Como o processo de integração dos dados ocorre em nível diferente daquele apresentado na fusão de dados, as características dos dados originais não são alterados. Segundo, a metodologia multifonte é fundamentada em conceitos estatísticos que permitem uma avaliação da acurácia e dos erros cometidos na classificação. Tal característica permite a análise da confiabilidade dos resultados de classificação

As classificações obtidas por meio da metodologia multifontes, em geral, apresentaram melhores resultados em relação aqueles produzidos pelas classificações monofontes, como era esperado. O aumento no valor da acurácia global foi observado. Mais uma vez, verificou-se por meio dos resultados que a utilização de informações provenientes de fontes distintas pode ser um fator positivo na classificação.

A definição do melhor resultado de classificação pode ser um conceito relativo pois depende fortemente do objeto em estudo. Como observado nas classificações geradas, o primeiro Cenário mostrou um ótimo resultado para o estudo da classe Floresta, porém, o segundo Cenário apresentou maior exatidão para o estudo da classe Solo Exposto.

Os resultados do terceiro Cenário não superaram os outros resultados em nenhuma das classes e o Cenário IV apresentou eficiência na identificação da classe Pasto. O Cenário final, relativo a metodologia *Fuzzy*, mostrou-se eficiente para o estudo de todas as classes além

de exibir baixas incertezas. Na classificação *Fuzzy* os resultados foram satisfatórios. O uso desta lógica na metodologia proposta foi um fator positivo por permitir uma classificação em classes mistas com baixa incerteza.

De forma geral, embora seja afirmado que não existe um método de integração de dados excelente, a definição de melhor técnica de integração de dados está diretamente ligada ao objeto em estudo. Mais estudos devem ser conduzidos na classificação multifontes com o objetivo de melhor caracterização desta metodologia. Neste trabalho utilizaram-se dois sensores, porém, esta técnica poderá ser estendida à w sensores distintos.

Por meio da metodologia proposta é factível identificar outras possibilidades de contribuições relevantes para a ciência na área de sensoriamento remoto no que diz respeito ao processamento digital de imagens, classificação de imagens, especificamente, na integração de dados multisensor, a saber:

apresentação de uma nova técnica de integração que torna possível a proposição e desenvolvimento de um classificador por regiões supervisionado multifontes capaz de obter resultados de classificações com melhores índices de acurácia;

exposição de uma nova metodologia de integração de dados que permite a redução das incertezas associadas às classificações; e

desenvolvimento de novas rotinas para *softwares* de tratamento de imagens e geoprocessamento tornando-se assim uma ferramenta adicional para o tratamento de dados espaciais.

AGRADECIMENTOS

Os autores agradecem à Mariane Reis pelos dados disponibilizados, à CAPES e ao CNPq (Processo: 303752/2013-0) pelo suporte financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

ABOUD NETA, S. R. **Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia.** (sid.inpe.br/mtc-m19/2009/11.19.09.48-TDI) Dissertação (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais (INPE), 2009. 264p.

ARAGÃO, L. E. O. C. **Modelagem dos**

- padrões temporal e espacial da produtividade primária bruta na região do Tapajós: uma análise multi-escala.** 286p. (INPE-11423-TDI/951). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2004.
- BRAGA, B. C.; FREITAS, C. C.; SANT'ANNA, S. J. S. Multisource classification based on uncertainty maps. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), Milan, Italy, 2015, **Proceedings...**2015a. pp.1630-1633.
- BRAGA, B. C.; FREITAS, C. C.; SANT'ANNA, S. J. S. Classificação multifontes de imagens de sensoriamento remoto baseada em mapas de incertezas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015b. p.4474-4481. ISBN 978-85-17-0076-8. Disponível em <<http://urlib.net/8JMKD3MGP6W34M/3JM4CQS>>. Acesso em: 9 set. 2015.
- BYUN, Y.; CHOI, J.; HAN, Y. An area-based image fusion scheme for the integration of SAR and optical satellite imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.6, n.5, pp.2212-2220, Oct. 2013.
- CÂMARA, G.; SOUZA, R. C. M.; FREITAS U. M.; GARRIDO, J. C. P. Spring: integrating remote sensing and GIS with object-oriented data modelling. **Computers and Graphics**, v.15, n.6, pp.13-22, 1996.
- CHAVEZ, P. S.; SIDES, S. C.; ANDERSON, J. A. Comparison of three different methods to merge multiresolution and multispectral data: TM & SPOT pan. **Photogrammetric Engineering and Remote Sensing**, v.57, pp.295-303, 1991.
- CSISZÁR, I. Information-type measures of difference of probability distributions and indirect observations. **Studia Scientiarum Mathematicarum Hungararica**, v.2, pp.299-318, 1967.
- ESCADA, M. I. S.; AMARAL, S.; RENNÓ, C. D.; PINHEIRO, T. F. **Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR-163.** 52p. (sid.inpe.br/mtc-m18@80/2009/04.24.14.45) São José dos Campos, 2009. Disponível em: <http://www.dpi.inpe.br/arquivos_pime/RPQ_PIME_20090422.pdf>. Acesso em: 05 out. 2014.
- FREITAS, C. C., SANT'ANNA, S. J. S., RENNÓ, C. D., CORREIA, A. H., **Utilização de imagens de radar de abertura sintética na classificação do uso e ocupação do solo**, in: EMBRAPA (org.). **Geomática: Técnicas e Aplicações Avançadas.**, 54p, 2003.
- FRERY, A. C.; NASCIMENTO, A. D. C.; CINTRA, R. J. Analytic expressions for stochastic distances between relaxed complex Wishart distributions. **IEEE Transactions on Geoscience and Remote Sensing**, v.52, n.2, pp.1213-1226, 2013.
- FURTADO, L. F. A.; SILVA, T. S. F.; FERNANDES, P. J. F.; NOVO, E. M. L. M. Land cover classification of Lago Grande de Curuai floodplain (Amazon, Brazil) using multi-sensor and image fusion techniques, **Acta Amazonia**, v.45, n.2, pp.195-202, 2015.
- GERSTL, S. A. W. Physics concepts of optical and radar reflectance signatures - A summary review. **International Journal of Remote Sensing**, v.11, n.7, pp.1109-1117, 1990.
- GUERRA, J. B. **Análise metodológica do tratamento de dados SAR R99B para discriminar incremento de desflorestamento no sudoeste da Amazônia brasileira.** (sid.inpe.br/mtc-m18/2009/02.18.14.18-TDI) Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), 2009. 199p.
- HAACK, B. N.; HEROLD N. D.; BECHDOL M. A. Radar and optical data integration for land-use/land-cover mapping. **Photogrammetric Engineering & Remote Sensing**. v.66, n.6, pp. 709-716, June 2000.
- HALL, D. L.; STEINBERG, A. N. Dirty secrets in multisensor data fusion. In: Hall, D.; Llinas, J. (eds.). **Multisensor data fusion**. New York: CRC Press, 2001. pp.21.1-21.16.
- IBAMA. **Floresta Nacional do Tapajós Plano de Manejo.** Informações gerais. Brasil: IBAMA, 2014. Disponível em: <http://www.icmbio.gov.br/portal/images/stories/imgsunidadescoservacao/flona_tapajoss.pdf>.

Acesso em: 13 out. 2014.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Catálogo LANDSAT5** 2013a. Disponível em: <<http://www.dgi.inpe.br>>. Acesso em: 12 jan. 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Biblioteca Digital de Fotos de Campo da OBT**. 2013b. Disponível em: <<http://www.obt.inpe.br/fototeca/>>. Acesso em: 9 out. 2014.

KUSSUL N.; SKAKUN S.; SHELESTOV A.; KRAVCHENKO O.; KUSSUL O. Crop classification in Ukraine using satellite optical and SAR images. **International Journal "Information Models and Analyses"**, v.2, n.2, pp.118-122, 2013.

LU, D.; LI, G.; MORAN, E.; DUTRA, L BATISTELLA, M. A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon, **GIScience & Remote Sensing**, v.48, n.3, pp.345-370, 2011.

LUZ, N. B.; ANTUNES, A. F. B.; TAVARES JÚNIOR, J. B. Segmentação multirresolução e classificação orientada a objetos aplicados a imagens SPOT-5 para o mapeamento do uso da terra. **Revista Floresta**, Curitiba, v.40, n.2, pp.429-446, abr./jun. 2010.

MOREIRA, M. L. O.; MEDEIROS, L. C.; COSTA, H. F. Integração de dados multifontes para mapeamentos temáticos. **Revista Geográfica Acadêmica**, v.1, n.1, pp.28-36, 2007.

NASCIMENTO, A. D. C. **Teoria estatística da informação para dados de radar de abertura sintética univariados e polarimétricos**. Tese (Doutorado em estatística) – Universidade Federal de Pernambuco, Recife, 2012. 280p.

PARIS, J. E.; KWONG, H. H. Characterization of vegetation with combined Thematic Mapper (TM) and Shuttle Imaging Radar (SIR-B) image data. **Photogrammetric Engineering Remote Sensing**, v.54, n.8, pp.1187-1193, 1988.

PEREIRA, L. O. **Avaliação de métodos de integração de imagens ópticas e de Radar para classificação do uso e cobertura da Terra na região Amazônica**. (sid.inpe.br/mct-m19/2012/08.30.12.50-TDI) Dissertação

(Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. 242p.

PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; LU, D.; MORAN, E. F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon **GIScience and Remote Sensing**, v.50, p.301-321, 2013.

POHL, C.; VAN GENDEREN, J. L. Multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing**, v.19, n.5, p.823-854, 1997.

REICHE J.; VERBESSELT J.; HOEKMAN D.; HEROLD M. Fusing Landsat and SAR time series to detect deforestation in the tropics. **Remote Sensing of Environment**, v.156, p.276-293, 2015.

REIS, M. S. **Deteção de mudanças de uso e cobertura da terra utilizando dados ópticos e de micro-ondas em uma região da Amazônia brasileira**. (sid.inpe.br/mct-m2b/2014/06.30.19.09-TDI) Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2014. 331p.

SALICRÚ, M.; MORALES, D.; MENENDEZ, M. L.; PARDO, L. On the applications of divergence type measures in testing statistical hypotheses. **Journal of Multivariate Analysis**, v.51, n.2, pp.372-391, Nov. 1994.

SCHISTAD-SOLBERG, A. H., JAIN, A. K., AND TAXT, T. Multisource classification of remotely sensed data: fusion of Landsat TM and SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v.32, p.768- 778, 1994.

SILVA, W. B. **Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas: aplicações a dados polarimétricos**. (sid.inpe.br/MCT-m19/2013/02.20.16-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2013. 143p.

SILVA, W., B.; FRERY, A. C.; FREITAS, C. C.; NEGRI, R. G.; SANT'ANNA, S. J. S. Classificador por regiões de imagens SAR com base em distâncias estocásticas derivadas da

densidade de probabilidade do par de intensidade *multi-look*. In: XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011 Curitiba. **Anais...** 2011 p.8326-8333.

SONG, C., WOODCOCK, C. E., SETO, K. C., LENNEY, M. P., MACOMBER, S. A., Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? **Remote Sensing of Environment**, v.75, n.2, pp.230-244, 2001.

SOUSA JR, M. A. **Segmentação multi-níveis e multi-modelos para imagens radar e ópticas.** (INPE - 14466-TDI/1147). Tese (Doutorado em Computação Aplicada) - Instituto Nacional

de Pesquisas Espaciais (INPE), São José dos Campos, 2005. 131p.

ULABY, F. T.; LI, R. Y.; SHANMUGAN, K. S. Crop classification using airborne radar and Landsat data. **IEEE Transactions on Geoscience and Remote Sensing**, v.20, pp.42- 51, 1982.

TROUVÉ, E.; VASILE, G.; GAY, M.; GRUSSENMEYER, P.; NICOLAS J. M.; LANDES, T.; KOEHL, M.; CHANUSSOT, J.; JULEA, A. Combining optical and SAR data to monitor temperate glaciers. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), Korea, South, 2005. **Proceedings...** 2005. pp.2637-2640.