

Classificação multifontes de imagens de sensoriamento remoto baseada em mapas de incertezas

Bruna Cristina Braga
Corina da Costa Freitas
Sidnei João Siqueira Sant'Anna

Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515-12245-970-São José dos Campos- SP, Brasil
bcbraga@dsr.inpe.br, {corina, sidnei}@dpi.inpe.br

Abstract. The image classification is one of the most remote sensing tools used for mapping the Earth's surface. There are several sensors for image acquisition, for instance the optical and the microwave. These sensors can generate data carrying distinct information. The jointly use of information provided by different sources is a big challenge. Therefore, it is necessary to develop specific techniques for processing and analyzing images generated by these distinguished sensors. Taking into account the information gathered by different sensors, in this work a statistic way to mix two classification results is evaluated. The information from an optical and a microwave sensors are mixed in order to improve the overall accuracy of the individual land-use and land-cover maps. The data were classified by a region based classifier employing stochastic distances and its statistic hypothesis test. In this classification process, besides the classified image is also generated an uncertainty map. The uncertainty map (it indicates the classification reliability) is used to generate three different classification scenarios. The first and second scenarios are related to the optical and microwave image classifications, respectively. The third scenario is result of mixing the classifications information provided by the both sensors. The overall accuracy was statistically equals to the optical classification result. The use of information provided by this distinct sources showed a positive impact in the final classification results because it diminishes the uncertainty. On the other hands it is important to perform more studies related to multisource classification to better evaluate this methodology.

Keywords: *multi source data, region based classifying, hypothesis tests, stochastic distance, uncertainty maps, dados multifontes, classificação por regiões, testes de hipótese, distância estocástica, mapas de incerteza*

1. Introdução

A necessidade de conhecer, mapear e monitorar os recursos naturais visando seu controle e utilização de forma racional tem incentivado a realização de projetos de levantamento e mapeamento da superfície terrestre. Entre as ferramentas de sensoriamento remoto e geoprocessamento utilizadas com esse objetivo encontra-se a classificação de imagens providas de sensores orbitais.

Estes sensores podem ser caracterizados através da faixa de frequência do espectro eletromagnético em que operam. Embora dentro do sensoriamento remoto a experiência com imagens obtidas por meio de sensores que operam na faixa do espectro denominado óptico seja maior, imagens providas de sensores de micro-ondas vêm sendo intensamente utilizadas. Os sensores que operam na faixa de micro-ondas possuem a vantagem de adquirirem dados independentemente da iluminação solar além de serem pouco influenciados pelas condições climáticas.

Sensores ópticos e de micro-ondas detectam informações diferentes, uma vez que, possuem características distintas no processo de formação de suas imagens. Por este motivo, se faz necessário o desenvolvimento de técnicas específicas para o processamento e a análise de cada uma destas imagens.

Silva (2013) desenvolveu uma ferramenta computacional para classificação de regiões de imagens de sensores remotos utilizando testes de hipóteses baseados em distâncias estocásticas. O classificador possui módulos que permitem a classificação tanto de imagens providas de sensores ópticos quanto de micro-ondas e, como um de seus diferenciais, fornece ao final do processo um plano de informação com valores-*p* correspondente às incertezas da classificação, que neste trabalho será denominado de mapa de incerteza.

Considerando a natureza complementar entre sensores operando nas faixas do óptico e micro-ondas, é possível utilizar dados oriundos de ambas as fontes em busca de informações mais completas para o estudo do uso e cobertura da terra. Diferente da operação de fusão, em que a informação é extraída diretamente dos dados, a abordagem proposta neste trabalho visa utilizar as informações obtidas a partir das classificações das imagens de sensores óptico e de micro-ondas, e gerar uma nova classificação com acurácia maior do que as individuais. Essa nova classificação e seu respectivo mapa de incerteza são construídos através dos mapas de classificação e de incertezas obtidos por meio do classificador por regiões desenvolvido por Silva (2013).

Este trabalho está organizado em seis seções. Na Seção 2, são descritos os fundamentos teóricos necessários para o entendimento das demais seções. O material utilizado e o método proposto são expostos na Seção 3. Um estudo de caso é discutido na Seção 4 e posteriormente, os resultados são delineados na Seção 5. Finalmente, na Seção 6 são apresentadas as considerações finais.

2. Fundamentação Teórica

Quando se trata da extração de informações do uso e cobertura da terra, o desenvolvimento de técnicas de classificação de imagens torna-se tarefa fundamental nas áreas de geoprocessamento e sensoriamento remoto. Nos últimos anos, tem havido grande interesse em se utilizar conceitos da Teoria da Informação para o desenvolvimento de técnicas de processamento digital de imagens e, especificamente, a classificação de imagens. Dentre estes conceitos podem-se citar as medidas de divergência.

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. Em Csiszár (1967) é desenvolvida a família de divergências ϕ , a qual é estendida em Salicrú et al. (1994) para 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. Uma evolução com relação ao estado da arte é a utilização de testes de hipóteses derivados de distâncias provenientes dessa divergência para fazer, dentre outros procedimentos possíveis, a classificação de imagens. Essa abordagem possui a vantagem de trazer uma medida de confiabilidade da classificação realizada, através da análise de valores- p dos testes utilizados. Na subseção 2.1 são apresentadas as distâncias provenientes de divergências $h-\phi$ e de testes de hipóteses associados às estas distâncias. O classificador por regiões desenvolvido por Silva et al. (2013), que utiliza estas distâncias é descrito na subseção 2.2.

2.1 Testes de Hipóteses com Base na Família de Distâncias $h-\phi$

Considere as variáveis aleatórias X e Y definidas sobre um mesmo domínio Ω com distribuições caracterizadas pelas densidades $f_X(x; \theta_1)$ e $f_Y(x; \theta_2)$ onde θ_1 e θ_2 são vetores de parâmetros. Segundo Salicrú et al. (1994) a divergência $h-\phi$ entre X e Y é dada 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 e $h: (0, \infty) \rightarrow [0, \infty)$ é uma função estritamente crescente com $h(0)=0$ e $h'(x) > 0$ para $\forall x \in \Omega$.

As medidas de divergência não são sempre simétricas, portanto não são sempre necessariamente distâncias. 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 $d_\phi^h(\theta_1, \theta_2) = 0$ se, e somente se, $\theta_1 = \theta_2$ e $d_\phi^h(\theta_1, \theta_2) \geq 0$. Salicrú et al. (1994) apresentou um meio para transformar distâncias em testes estatísticos com propriedades assintóticas conhecidas. Dados $\hat{\theta}_1 = (\hat{\theta}_{11}, \dots, \hat{\theta}_{1M})$ e $\hat{\theta}_2 = (\hat{\theta}_{21}, \dots, \hat{\theta}_{2M})$, estimadores de máxima verossimilhança 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 estatística de teste de hipótese S_ϕ^h conforme a equação

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

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 utilizada. Obedecendo a condições específicas de regularidade, se $m, n \rightarrow \infty$ e $\theta_1 = \theta_2$ então

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

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_i ($i = 1, 2$). 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 $s = S_\phi^h(\hat{\theta}_1, \hat{\theta}_2)$.

2.2 Classificador por regiões baseado em distâncias estocásticas

Uma das mais clássicas abordagens empregadas na classificação por regiões de imagens 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. Em geral é feita a suposição que os dados seguem uma distribuição Gaussiana multivariada. 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 por regiões supervisionadas (SILVA, 2013). Em Silva (2013) e Silva et al. (2013) é apresentado um classificador por regiões baseado em distâncias estocásticas. Este classificador possui vários diferenciais 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 incerteza 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 densidade de probabilidade além da gaussiana multivariada, tais como a função Wishart, utilizada para modelar a matriz de covariância de dados de radar de abertura sintética (*Synthetic Aperture Radar* - SAR) polarimétricos. Abaixo 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 pixel pertencentes a estes segmentos possuam uma função densidade de probabilidade $f(x; \theta)$, em que θ é o vetor de parâmetros. Suponha também que para cada segmento C_i , com $1 \leq i \leq r$, os vetores de parâmetros $\hat{\theta}_i$ sejam estimados pelo método de máxima verossimilhança. 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 da função densidade de probabilidade considerada. 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, o qual p representa a confiabilidade da classificação obtida (SILVA, 2013).

O classificador desenvolvido por Silva (2013) dispõe de três módulos: (1) Imagens Polarimétricas, (2) Par de Imagens SAR em intensidade e (3) Imagens ópticas e SAR multivariadas em amplitude, cada um apropriado à modelagem estatística mais adequada a diferentes tipos de dados. Neste trabalho utilizou-se o módulo para imagens multivariadas em amplitude com modelagem estatística Gaussiana e distância estocástica de Bhattacharyya. Neste módulo podem ser classificadas imagens ópticas e SAR.

3. Material e Método

3.1 Dados

A área em estudo corresponde à parte da Floresta Nacional (Flona) 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. Nesta área foram selecionadas duas imagens, uma óptica e outra de micro-ondas. A imagem óptica é oriunda do sensor *Thematic Mapper* (TM) do satélite LANDSAT5 adquirida em 29 de junho de 2010, enquanto a de micro-ondas foi adquirida em 21 de junho de 2010 pelo sensor *Phase Array L-Band Synthetic Aperture Radar* (PALSAR) do satélite *Advanced Land Observing System* (ALOS) nas polarizações HH e HV. Estas imagens foram pré-processadas de acordo com o trabalho de Reis (2014), do qual se obteve também as imagens segmentadas e as amostras de treinamento e de teste das classes de cobertura da terra usadas no processo de classificação. As imagens do LANDSAT5/TM e do ALOS/PALSAR foram registradas entre si gerando imagens de 916 por 1996 pixels com resolução espacial de 15 m.

Na segmentação da imagem PALSAR utilizou-se o algoritmo denominado SegSAR (SOUZA JR, 2005). Adotou-se no processo de segmentação o modelo de manchas, similaridade de 1,0 db, área mínima de 20 pixels e nível de confiabilidade de 95%. Para a segmentação da imagem TM, as bandas 2, 4 e 5 foram normalizadas para média=127 e desvio padrão=42 e utilizou-se o algoritmo *Multiresolution Segmentation (E-Cognition)* com os seguintes parâmetros: forma e compacidade iguais a 0,3 e parâmetro de escala igual a 30. Estas imagens segmentadas (de cada sensor) foram combinadas, gerando uma única imagem segmentada contendo 17568 segmentos, na qual áreas menores que 20 pixels agrupadas com uso da ferramenta rotulação de componentes conectados do SPRING 5.2.2.

3.2 Classificação por regiões

Para aplicação da metodologia a ser descrita, adotaram-se cinco classes que correspondem aos resultados do agrupamento das classes apresentadas em 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 áreas em Pousio.

O classificador utilizado recebe como dados de entrada a imagem a ser classificada, uma imagem segmentada (imagem de regiões), amostras de teste e de treinamento. Após sua execução, o programa retorna a imagem classificada e um mapa de incertezas indicativo da qualidade da classificação final. Esse mapa de incerteza indica os segmentos para os quais a hipótese nula do teste não foi rejeitada ao nível de significância de 5%.

3.3 Estudo de caso

A metodologia adotada originou três Cenários de classificação e seus mapas de incertezas a partir dos resultados individuais das classificações das imagens LANDSAT5/TM e ALOS/PALSAR e de seus respectivos mapas de incertezas. A origem dos Cenários de classificação seguiu a metodologia apresentada a seguir.

Considere um conjunto A formado por Y diferentes imagens que se deseja classificar em k classes. Considere também uma única segmentação dessas imagens em r segmentos (regiões). Para cada imagem y , $y \in \{1, 2, \dots, Y\}$ e a cada região i , $i \in \{1, 2, \dots, r\}$ pode ser calculado um vetor de atributos $C_{ij}^y = (p_{ij}^y, s_{ij}^y)$, $j \in \{1, 2, \dots, k\}$. Os atributos p_{ij}^y (probabilidade) e s_{ij}^y (estatística) indicam a incerteza da possível atribuição da classe j à região i na imagem y . Diferentes classificações e mapas de incerteza associados à imagem y podem ser gerados a partir de funções dos elementos dos vetores de atributos C_{ij}^y . Cada uma dessas classificações é denominada aqui Cenário de classificação.

Neste trabalho, o conjunto A é formado pelas imagens LANDSAT5/TM (T) e ALOS/PALSAR (R) ($A = \{T, R\}$) e foram classificadas nas 5 classes levando-se em conta as 17568 regiões da imagem segmentada. C_{ij}^T e C_{ij}^R , $i \in \{1, 2, \dots, 17568\}$, $j \in \{1, 2, \dots, 5\}$ representam os vetores de atributos para estas imagens, como descrito acima. Os seguintes Cenários foram construídos:

Cenário I: corresponde à classificação da imagem LANDSAT5/TM e de seu respectivo mapa de incerteza. Para cada região i é atribuída a classe l que possui menor s_{ij}^T , $j \in \{1, 2, \dots, 5\}$. O mapa de incertezas é formado pelas incertezas s_{ii}^T associadas às classificações das regiões i na classe l .

Cenário II: corresponde à classificação da imagem ALOS/PALSAR e de seu respectivo mapa de incerteza. Para cada região i é atribuída a classe v que possui menor s_{ij}^R , $j \in \{1, 2, \dots, 5\}$. O mapa de incertezas é formado pelas incertezas s_{ii}^R associadas às classificações das regiões i na classe v .

Cenário III: corresponde à classificação utilizando informações de ambas as imagens LANDSAT5/TM e ALOS/PALSAR, e de seus respectivos mapas de incerteza. Para tal, é formado o vetor de atributos $C_{ij}^{TR} = C_{ij}^T * C_{ij}^R$, onde $*$ indica o produto escalar de dois vetores. Neste Cenário, para cada região i é atribuída a classe e que possui menor s_{ij}^{TR} , $j \in \{1, 2, \dots, 5\}$. O mapa de incertezas é formado pelas incertezas s_{ie}^{TR} associadas às classificações das regiões i na classe e .

4. Resultados

A classificação da imagem LANDSAT5/TM e seu mapa de incertezas correspondentes ao Cenário I são apresentados na Figura 1.

Analisando o resultado da classificação e seu respectivo mapa de incertezas, observa-se que a incerteza foi menor para as classes Regeneração e Floresta neste cenário. Na matriz de confusão, calculada a partir das amostras de teste, verificam-se os erros de comissão (inclusão) e omissão (exclusão) efetuados pelo classificador assim como a porcentagem de

acertos para cada classe estudada (diagonal principal). Para a classe Floresta, por exemplo, a exatidão foi 100%, ou seja, todos os pixels das amostras de teste associados a esta classe foram classificados corretamente. Já no caso da classe Pasto, a exatidão foi de 89,94% e constata-se que parte das amostras foi classificada como pertencente às classes Soja, Regeneração ou Solo exposto, caracterizando erros de omissão. Nota-se também que parte dos elementos pertencentes à classe Soja foi classificado como Pasto, caracterizando um erro de comissão para a classe Pasto.

A classificação da imagem ALOS/PALSAR e seu mapa de incertezas, correspondente ao Cenário II, são apresentados na Figura 2. A classificação da imagem proveniente do sensor de micro-ondas apresenta um grau de incerteza maior em relação ao Cenário anterior, provavelmente devido ao ruído *speckle*, característico desse tipo de sensor. A matriz de confusão para o Cenário II (Figura 2) apresenta exatidão inferior ao do Cenário I na maior parte das classes. A classe Solo Exposto, entretanto, foi melhor classificada neste Cenário.

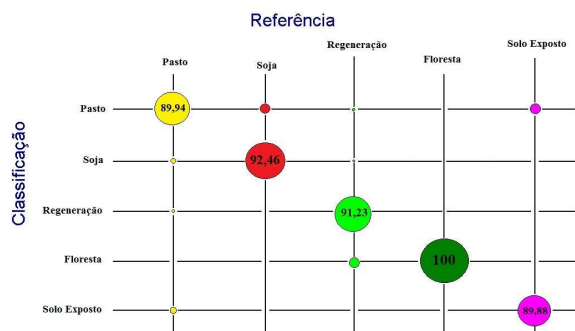
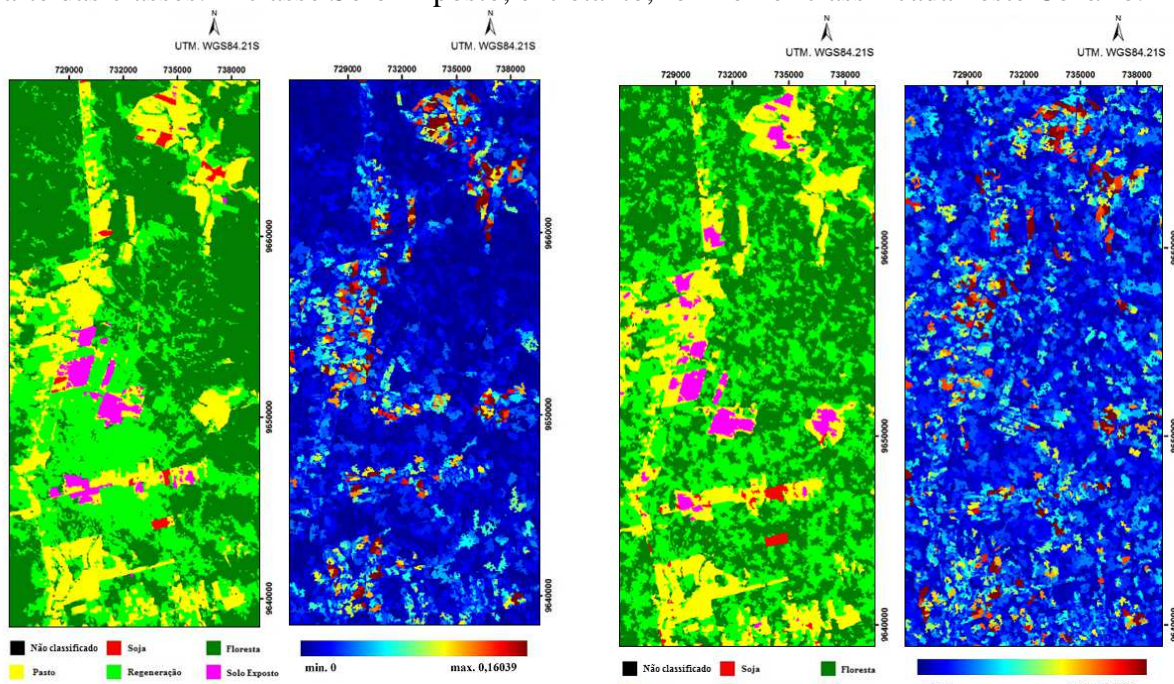


Figura 1: Imagem classificada correspondente ao Cenário I, mapa de incertezas e a matriz de confusão associada à classificação.





Figura 2: Imagem classificada correspondente ao Cenário II, mapa de incertezas e a matriz de confusão associada à classificação.

A classificação e respectivo mapa de incertezas correspondentes ao Cenário III são apresentados na Figura 3. Este Cenário possui o melhor resultado de classificação considerando-se as incertezas, porém, sua matriz de erros mostra maior exatidão apenas para a classe Pasto em relação aos outros Cenários de classificação.

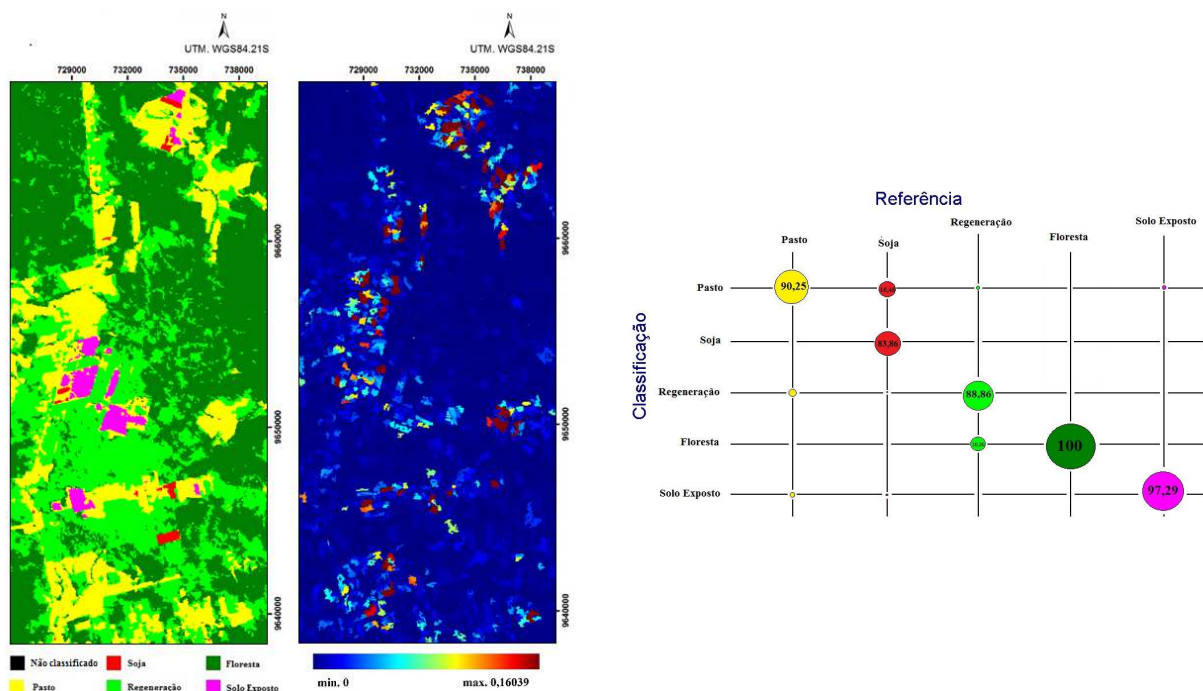


Figura 3: Imagem classificada correspondente ao Cenário III, o mapa de incertezas e a matriz de confusão associada à classificação.

Na Tabela 1 são mostrados os erros relativos às classificações originadas e na Tabela 2 os valores de acurácia global e coeficiente *kappa* para estes Cenários. Relacionando os resultados do Cenário II com o Cenário III verifica-se melhor acurácia global e maiores acertos no Cenário III exceto para a classe Solo Exposto em que o Cenário II superou tanto o Cenário I quanto o Cenário III. Também se verifica no Cenário III a redução dos erros de comissão em relação aqueles apresentados no Cenário II.

Tabela 1: Acertos e erros relativos às classificações.

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

Tabela 2: Coeficiente de determinação *kappa* e acurácia global dos resultados.

Classificação	<i>kappa</i>	Variância do <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	0,88	$2,64 \times 10^{-4}$	0,92

Ao defrontar os Cenários I e III atenta-se que, em questão de acertos, a classe Floresta Primária foi classificada com 100% de exatidão por ambos os Cenários, porém, o erro de comissão desta classe foi menor para o Cenário I enquanto o erro de omissão foi nulo para ambos os Cenários. As classes Pasto e Solo Exposto foram mais bem classificadas no Cenário III e as classes Soja e Regeneração no Cenário I, sendo que a classe Regeneração possui menores erros de omissão e comissão também para este Cenário. Na Tabela 2 é possível

observar que os coeficientes *kappa* dos Cenários I e III são estatisticamente iguais e que a acurácia global de ambos os cenários é a mesma. Contudo, observando-se o mapa de incertezas das Figuras 1 e 3, pode-se notar que o Cenário III apresentou valores de incertezas menores do que aqueles exibidos no mapa correspondente à classificação do Cenário I.

5. Considerações Finais

A utilização de informações provenientes de fontes distintas pode ser um fator positivo na classificação, pois além de agregar diferentes informações ao resultado final, pode reduzir a incerteza associada à classificação.

A melhor classificação é aquela que discrimina melhor as suas classes de interesse. Como observado nas classificações geradas, o Cenário I sugeriu ótimo resultado para o estudo da classe Regeneração enquanto, o Cenário II apresentou maior exatidão para o estudo da classe Solo Exposto. O Cenário III mostrou bons resultados para o estudo da classe Pasto e embora tenha resultado em uma classificação com menor incerteza, seu coeficiente *kappa* e sua acurácia global são estatisticamente iguais às daquelas do Cenário I.

Mais estudos devem ser conduzidos na classificação multifontes para uma completa validação do método. Outras metodologias devem ser analisadas como, por exemplo, a mesclagem de informações de imagens oriundas de diferentes sensores de micro-ondas que operam em frequências distintas.

Os resultados obtidos por meio desta nova metodologia de conjugação de informações oriundas de diferentes fontes de dados de sensoriamento remoto poderão servir como base para o desenvolvimento de novas rotinas para *softwares* de tratamento de imagens e geoprocessamento tornando-se assim uma ferramenta adicional para o tratamento de dados espaciais.

6. Agradecimentos

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

7. Referências Bibliográficas

CSISZÁR, I. Information-type measures of difference of probability distributions and indirect observations.

Studia Sci. Math. Hungar. v.2, p.299-318, 1967.

REIS, M. S. **Detecção de mudanças de uso e Cobertura da Terra utilizando dados óticos e de Micro-ondas em uma região da Amazônia Brasileira.** 2014. 331 p. (sid.inpe.br/mtc-m21b/2014/06.30.19.09-TDI).

Dissertação (Mestrado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2014.

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, p. 372-391, Nov. 1994.

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

SILVA, W. B. ; FREITAS, C. C. ; SANT'ANNA, S. J. S. ; FRERY, A. C. . Classification of Segments in PolSAR Imagery by Minimum Stochastic Distances Between Wishart Distributions. **IEEE J-STARS**, v. 6, p. 1263-1273, 2013.

SOUSA JR, M. **Segmentação multi-níveis e multi-modelos para imagens radar e ópticas.** 2005. 131 p. (INPE - 14466-TDI/1147). Dissertação(Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2005.