

Integração de imagens Radarsat-2 e Alos/Palsar para obtenção de classificações multifontes do uso e cobertura da terra

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

Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
bruna.braga@inpe.br, {sidnei, corina}@dpi.inpe.br

Abstract.

In this paper two SAR images (acquired by different frequency) are integrated using a methodology called "multisource classification". The technique allows the generation of different classification scenarios (classification and reliability map). This different scenarios were combined in order to obtain better classification results by using the minimum function compounding the scenario multisource minimum. One RADARSAT-2 (C-band) and one ALOS/PALSAR (L-band) images were used in this study. These images were modeled by the complex Wishart or multi-look intensity pair distributions. From the fourteen generated multisource scenarios, ten showed improvement greater than 10% related to the corresponding individual ratings. It was noted that for these scenarios both images had been modeled by the same distribution and for four remaining cases each data were modeled by a specific distribution. Two multisource scenarios did not presented overall accuracy and kappa coefficient higher than the individual classification however they exhibited high values of accuracy for Intermediate Regeneration class. The results showed that our method is effective to improve the classification accuracy indexes when SAR images are multisource integrated.

Palavras-chave: *stochastic distance, hypothesis tests, region based classifying, minimum scenario, distâncias estocásticas, teste de hipóteses, classificação por regiões, cenário dos mínimos.*

1. Introdução

A classificação de imagens de sensores remotos é uma importante técnica do processamento de imagens que tem sido utilizada para o estudo e monitoramento das várias coberturas presentes na superfície terrestre. No que diz respeito aos dados empregados para classificação, sabe-se que imagens provenientes de sensores ópticos são frequentemente usadas, carregam informações acerca de propriedades físico-químicas dos alvos e resultam em classificações com altos valores de acurácia global. Contudo, suas limitações provenientes das condições meteorológicas conduz a utilização de imagens de sensores que operam na faixa de microondas. Essas imagens contém informações sobre as propriedades dielétricas e geometria (forma, textura e estrutura) dos alvos e possuem diversas vantagens quando comparadas às ópticas, tais como, maior sensibilidade à variações na morfologia da superfície, geometria de aquisição controlada e possibilidade de imageamento noturno (PARADELLA, 1996). Além disso, na maioria das vezes, a alta ocorrência de nuvens, chuva ou fumaça em determinadas regiões não afetam a aquisição de dados, ao contrário do que ocorre com imagens ópticas.

Os radares de abertura sintética (SAR) operam em diferentes frequências (ou bandas) e seus dados são utilizados com propósitos diversos. Para sensores que operam nas bandas C ou L, por exemplo, entre as principais aplicações pode-se citar o estudo do impacto das atividades humanas sobre o meio ambiente e o monitoramento de recursos naturais. Todavia, algumas diferenças são observadas nas imagens SAR adquiridas nessas bandas específicas. Exemplificando, em regiões desmatadas, áreas desflorestadas e preservadas tendem a ter aspectos equivalentes na banda C, ao passo que na banda L, áreas desflorestadas geralmente são mais escuras (menor retorno do sinal) e áreas preservadas

são mais claras (maior retorno do sinal). Considerando-se estes fatos, ou seja, a quantidade de sensores SAR disponíveis operando em frequências variadas e as informações que seus dados contêm, lança-se a seguinte pergunta: é possível melhorar a acurácia global de uma dada classificação de imagem de microondas por meio do uso conjunto de imagens SAR operando em diferentes bandas?

Recentemente, apresentou-se na literatura um novo procedimento de integração de dados para obtenção de melhores resultados de classificação de imagens (BRAGA, 2016). O método estatístico denominado “classificação multifontes” baseia-se em distâncias estocásticas e testes de hipóteses associados, permitindo assim, a construção de diferentes classificações e de seus respectivos mapas de confiabilidade que indicam a certeza da classificação (BRAGA *et al.*, 2015a). Portanto, neste Trabalho analisam-se os diferentes resultados de classificação obtidos por meio de classificações multifontes entre duas imagens SAR provenientes de sensores com bandas distintas (C e L) ao variar-se a distribuição que modela os dados. As classificações de imagens de microondas, várias vezes, apresentam baixos valores de acurácia global. Desta forma, busca-se neste trabalho, a aquisição de maiores valores de acurácia global e acurácia por classe ao aplicar-se a metodologia multifontes proposta. Espera-se que tais resultados, se obtidos, reflitam melhorias nas classificações individuais das imagens.

2. Área de estudo e dados utilizados

A área de estudo pode ser visualizada na Figura 1. Essa é uma importante unidade de conservação que se encontra no estado do Pará/Brasil e corresponde à parte da Floresta Nacional do Tapajós.

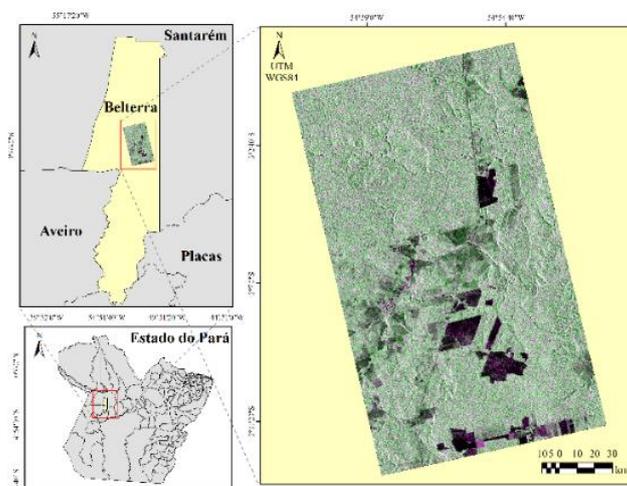


Figura 1. Localização da área de estudo e recorte da imagem SAR (radarsat-2) de 19 de setembro de 2009 em composição colorida hh(R), hv(G), hh(B).

Para aplicação da metodologia, utilizaram-se duas imagens SAR complexas, uma imagem com as quatro polarizações (hh, hv, vh, vv) proveniente do sensor radarsat-2 datada de 19 de setembro de 2009 (banda C) e uma imagem com duas polarizações (hh, hv) do sensor *Phase Array L-Band Synthetic Aperture Radar* (palsar) a bordo do satélite *Advanced Land Observing System* (alos) datada de 03 de agosto de 2009.

3. Metodologia

A “classificação multifontes” é um procedimento supervisionado que se baseia em uma técnica estatística para classificar regiões de imagens. Neste processo, calculam-se distâncias estocásticas (d), estatísticas de teste (s) e p -valores entre a distribuição conjunta que modela os pixels presentes nas amostras representativas das classes em estudo (f_1) e a distribuição

conjunta que modela os pixels contidos nas regiões da imagem (f_2) (BRAGA, 2016). Este processo de classificação é descrito brevemente abaixo.

Sejam w imagens georeferenciadas e corregistradas entre si de uma mesma região. Considere também uma única segmentação com r segmentos disjuntos válida para as w imagens e k classes de uso e cobertura da terra. Conhecidas as distribuições de probabilidade que modelam os dados envolvidos e a distância estocástica entre essas distribuições, é possível calcular estatísticas de teste e p -valores entre essas distribuições por meio da equação:

$$S(f_1, f_2) = \frac{2mnv}{m+n} d(f_1, f_2) \xrightarrow{D} \chi_M^2, \quad (1)$$

em que S representa a estatística de teste entre as distribuições f_1 e f_2 , m é o tamanho da amostra representativa da região e n é o tamanho da amostra correspondente à classe, v é uma constante que depende da distância estocástica (d) entre distribuições (f_1 e f_2) adotada. Sabe-se que sob determinadas condições de regularidade, se m e n forem suficientemente grandes, as estatísticas de teste convergem em distribuição (\xrightarrow{D}) a uma qui-quadrado com M graus de liberdade (χ_M^2), onde M representa os números de parâmetros estimados da distribuição. A partir de tal resultado é possível aplicar testes de hipóteses cuja hipótese nula ($f_1 = f_2$) é rejeitada ao nível de significância η se $\Pr(\chi_M^2 > s) \leq \eta$ em que $s = S(f_1, f_2)$ e $p = \Pr(\chi_M^2 > s)$ representa o p -valor do teste. Na Figura 2 ilustra-se o esquema de classificação empregado para construção do cenário multifontes denominado cenário dos mínimos. Um cenário de classificação é composto por uma imagem classificada acompanhada de um mapa de confiabilidade da classificação (BRAGA *et al.*, 2015a).

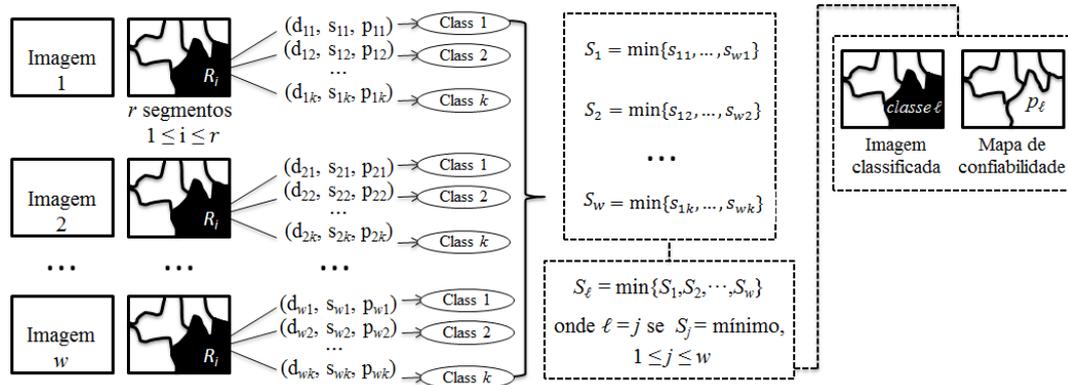


Figura 2. Processo de classificação para construção do cenário multifonte dos mínimos.

Neste cenário, fixada a região i , observa-se que, para cada uma das w imagens, após os cálculos das k triplas (d, s, p) , seleciona-se a mínima estatística s entre as k estatísticas calculadas. Desta forma, se para a imagem 1, a mínima estatística ($S_{1,}$) corresponder à classe 2, atribui-se esta classe à região fixada, isto é, por meio dos resultados obtidos (S_1, S_2, \dots, S_w) constroem-se as classificações monofontes das imagens. Todavia, na técnica multifontes, dá-se continuidade ao processo e após o cálculo das mínimas estatísticas para cada imagem (mínima estatística local) seleciona-se a mínima estatística entre todas calculadas (mínima estatística global). Neste caso, se a mínima estatística corresponder à imagem ℓ , atribui-se à região em questão a mesma classe estabelecida para esse segmento na classificação monofonte da imagem ℓ . Repetindo consecutivamente esse processo para todas as regiões da imagem obtém-se a classificação multifonte dos mínimos e os p -valores relativos as estatísticas finais irão compor o mapa de confiabilidade da classificação. Cabe ressaltar que a classificação individual (monofonte) das imagens torna-se similar àquela desenvolvida por Silva (2013).

As distribuições *Wishart* complexa escalonada (W_i) e Par de intensidades *multi-look* (P_i) foram adotadas na modelagem dos dados SAR. Para o cálculo das distâncias entre estas distribuições admitiu-se a distância estocástica de *Bhattacharyya*.

Para representação dos dados e de sua modelagem, utilizou-se a seguinte notação: {imagem, modelagem, polarizações}. Desta forma, uma imagem alos/palsar (P), modelada por meio da distribuição Par de intensidades, fixada a distância de *Bhattacharyya* com polarizações hh e hv é representada por $\{P, P_i, hh, hv\}$.

3.1 Dados

Na primeira etapa do pré-processamento dos dados, extraiu-se da imagem radarsat (radarsat-2) a matriz de covariância C_3 . Para a imagem palsar (alos/palsar), gerou-se a matriz de covariância C_2 nas polarizações hh e hv. Em ambos os casos, no processo de geração da matriz, aplicaram-se fatores de compressão para as colunas e linhas das imagens projetando estas, inicialmente em *slant range* para *ground range*. Os fatores de compressão aplicados foram 1×5 para a imagem palsar e 3×6 para a imagem radarsat.

A imagem palsar foi corregrada à radarsat e posteriormente recortou-se a área comum às duas resultando em imagens com resolução de 15×15 m e dimensões 1217×1682 pixels. Estimou-se o número equivalente de *looks* das imagens palsar e radarsat encontrando-se 3 e 8, respectivamente. Para fins de avaliação os seguintes conjuntos de dados foram utilizados: matriz de covariância radarsat C_3 , matriz de covariância palsar C_2 , matriz de covariância radarsat C_2 relativa às polarizações hh e hv, matriz de covariância radarsat C_2 hh e vv, matriz de covariância radarsat C_2 vv e hv, par de intensidades hh e hv radarsat, par de intensidades hh e vv radarsat, par de intensidades hv e vv radarsat e par de intensidades hh e hv palsar. Para modelagem das matrizes C_2 e C_3 utilizou-se a distribuição *Wishart* complexa escalonada e para a modelagem dos pares de intensidades utilizou-se a distribuição Par de Intensidades *multi-look* (SILVA, 2013).

A segmentação (contendo 14369 regiões) adotada foi construída por meio da união das segmentações individuais das imagens. Após a unificação passou-se um filtro de áreas mínimas gerando regiões com número de pixels superiores a 50.

As classes de uso e cobertura empregadas neste trabalho foram: Floresta Primária (FP), Regeneração Intermediária (RM), Regeneração Inicial (RI), Agricultura (AG), Pasto Sujo (PS), Pasto Limpo (PL) e Solo Exposto (SE). Para coleta das amostras das classes utilizaram-se dados de campo de 2009 e uma imagem SPOT de 11 de setembro de 2009. Na estimação dos parâmetros das distribuições que modelam os dados, todas as amostras (segmentos e classes) foram subamostradas usando *lag* 2.

4. Resultados e discussões

Na Tabela 1 visualizam-se os valores de acurácia global e coeficiente *kappa* obtidos para as classificações monofontes das imagens SAR ao variar-se a modelagem e o tipo de dado. Na Tabela 2 apresentam-se os índices de acurácia (acurácia global e coeficiente *kappa*) para os diferentes cenários multifontes dos mínimos construídos, combinando-se duas a duas as modelagens mostradas na Tabela 1. Nas Figuras 3 e 4 são exibidos, respectivamente, a acurácia global e erros cometidos para os cenários dos mínimos que resultaram nos maiores índices de melhora quantitativa da classificação - *QIC* (casos I e XI) em relação aos resultados monofontes associados. As classificações e mapas de confiabilidade correspondentes podem ser visualizados na Figura 5. Por meio do *QIC* ($QIC = [k_b - k_a] / [1 - k_a]$) é possível avaliar o quanto o resultado de uma classificação b pode ser melhorado relativamente ao resultado de uma classificação a (BRAGA *et al.*, 2015b). Para o computo deste índice utilizam-se os coeficientes *kappas* das classificações.

Para a imagem palsar, os maiores índices de acurácia são obtidos quando admite-se a distribuição Par de intensidades para modelar os dados. Para a imagem radarsat, os índices são superiores para o caso em que se adota a distribuição *Wishart* para a modelagem da matriz C_2 relativa às polarizações hh e vv. A matriz C_3 radarsat resultou nos segundos maiores índices de acurácia de classificação.

Os casos I e XI foram os que exibiram os maiores índices de melhora quantitativa de classificação (*QIC*) sendo estes superiores a 10% em relação a ambas as classificações individuais correspondentes. Embora os valores atingidos por ambos os casos apresentem coeficientes *kappas* iguais, as melhorias dos resultados obtidos para cada uma das classes variam entre eles. Observe que para os casos I e XI, embora os cenários monofontes sejam o mesmo para a imagem palsar, para a imagem radarsat, esses cenários variam.

Na Figura 3 são apresentadas as acurácias por classe obtidas para as classificações das imagens palsar, radarsat e para os cenários multifontes dos mínimos para os casos I e XI. Nota-se que, no caso I, a acurácia por classe foi superior a ambas as individuais para as classes Floresta Primária e Solo Exposto, manteve os maiores valores para as classes Agricultura e Pasto Sujo. No caso XI, as classes Floresta Primária e Regeneração Intermediária apresentaram acurácia maiores que as individuais.

Tabela 1. Índices de acurácia para os cenários monofontes variando-se as modelagens dos dados.

Cenários monofontes		
Cenários	Acurácia Global (%)	Coefficiente <i>kappa</i>
{P, P_i, hh hv}	55,49	0,42
{P, W_i , hh hv}	42,81	0,28
{R, P_i , hh hv}	38,94	0,30
{R, P_i , hh vv}	27,86	0,21
{R, P_i , hv vv}	30,41	0,22
{R, W_i , hh hv}	33,98	0,26
{R, W_i, hh vv}	43,15	0,34
{R, W_i , hv vv}	32,60	0,23
{R, W_i , hh hv vv}	40,18	0,31

Tabela 2. Índices de acurácias e índice de Melhora Quantitativa da Classificação (*QIC*) para os cenários multifontes dos mínimos.

Caso	Combinação multifonte		Acurácia Global (%)	Coefficiente <i>kappa</i>	<i>QIC</i> Palsar (%)	<i>QIC</i> Radarsat (%)
	Palsar	Radarsat				
I	{P, P_i, hh hv}	{R, P_i, hh hv}	61,37	0,49	12	27
II	{P, W_i , hh hv}	{R, P_i , hh hv}	47,06	0,34	8	6
III	{P, P_i , hh hv}	{R, W_i , hh hv vv}	47,96	0,35	-*	6
IV	{P, W_i , hh hv}	{R, W_i , hh hv vv}	48,16	0,34	8	4
V	{P, P_i , hh hv}	{R, W_i , hh vv}	49,16	0,38	-*	6
VI	{P, W_i , hh hv}	{R, W_i , hh vv}	48,54	0,35	10	2
VII	{P, W_i , hh hv}	{R, W_i , hh hv}	47,21	0,34	8	11
VIII	{P, W_i , hh hv}	{R, W_i , hv vv}	46,14	0,32	6	12
IX	{P, P_i , hh hv}	{R, W_i , hh hv}	36,06	0,27	-*	1
X	{P, P_i , hh hv}	{R, W_i , hv vv}	40,84	0,29	-*	8
XI	{P, P_i, hh hv}	{R, P_i, hh vv}	61,55	0,49	12	35
XII	{P, W_i , hh hv}	{R, P_i , hh vv}	44,20	0,30	3	11
XIII	{P, P_i , hh hv}	{R, P_i , hv vv}	57,90	0,44	3	28
XIV	{P, W_i , hh hv}	{R, P_i , hv vv}	47,04	0,33	7	14

* correspondem aos *QIC* negativos que não apresentaram melhorias na classificação.

Na Figura 4, em relação aos erros de comissão e omissão para as imagens palsar (CP, OP), radarsat (CR, OR) e para os cenários multifontes resultantes dos casos I (CCI, OCI) e XI (CCXI, OCXI), observa-se que os erros de comissão foram menores para as classes Agricultura e Pasto Limpo no caso I e para as classes Regeneração Intermediária, Agricultura e Pasto Sujo no caso XI. Os erros de omissão foram menores para as classes Floresta Primária e Solo Exposto no caso I e Floresta Primária e Regeneração Intermediária no caso XI.

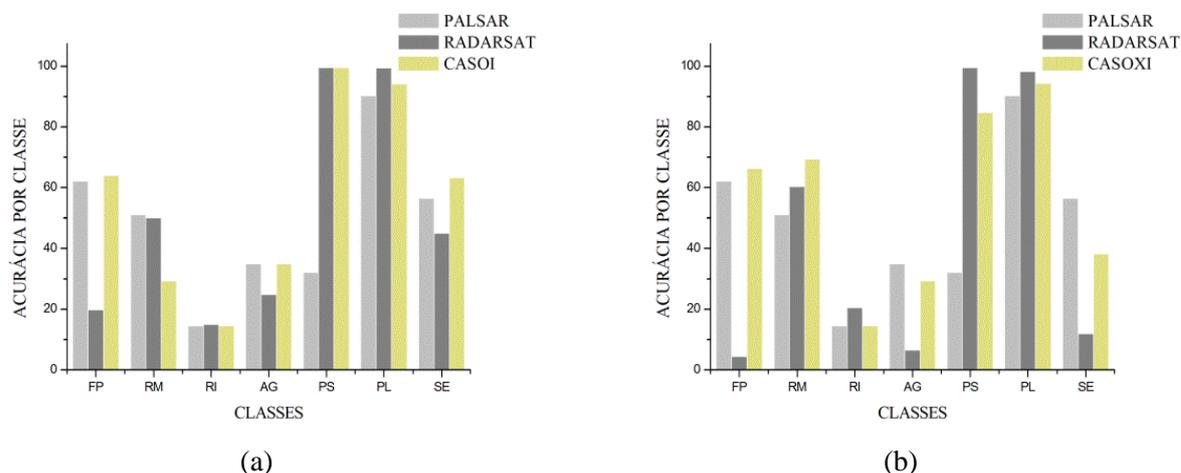


Figura 3. Relação entre a acurácia por classe para os cenários multifontes dos mínimos para os casos I (a) e XI (b) em relação as acurácias por classe para as classificações individuais associadas.

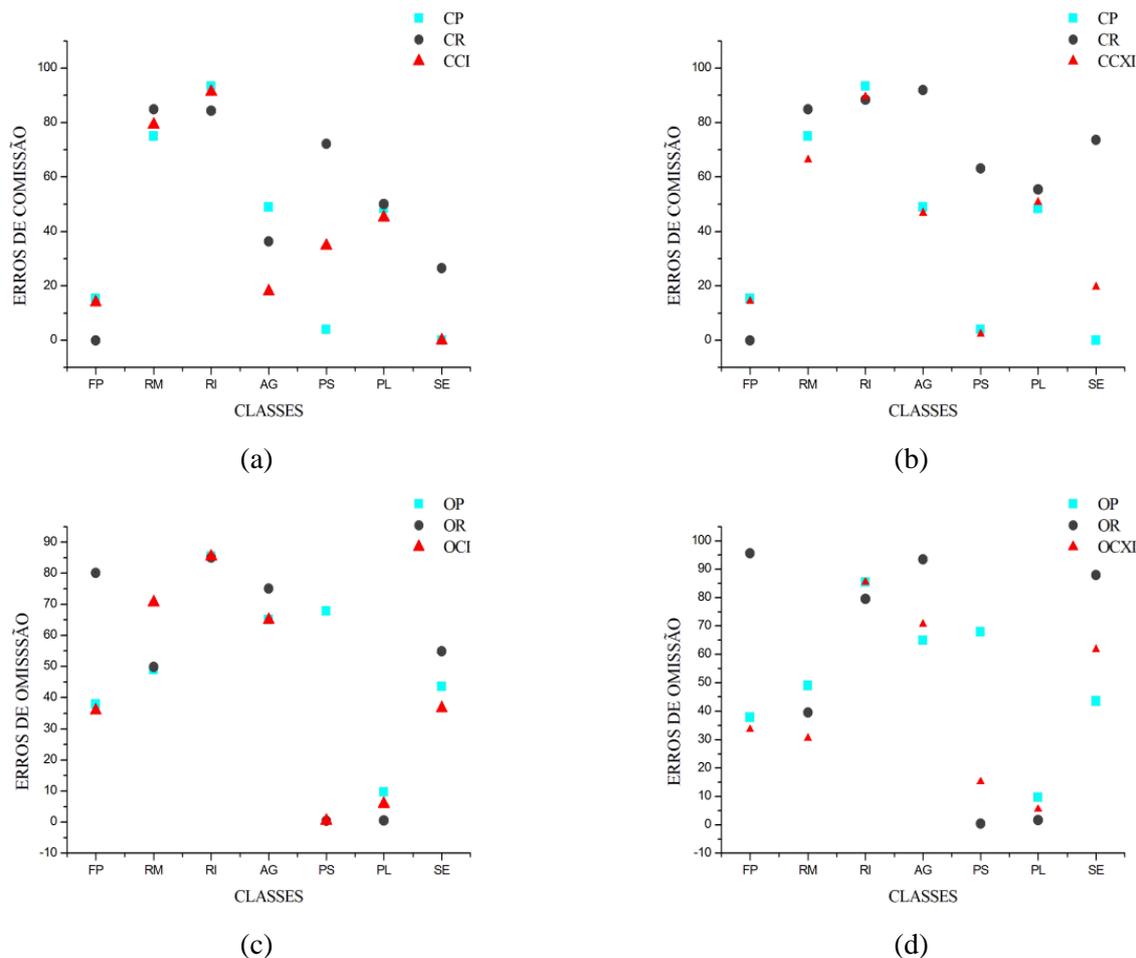


Figura 4. Relação entre os erros por classe para os cenários multifontes dos mínimos para os casos I (a, c) e XI (b, d) em relação aos erros por classe das classificações individuais correspondentes.

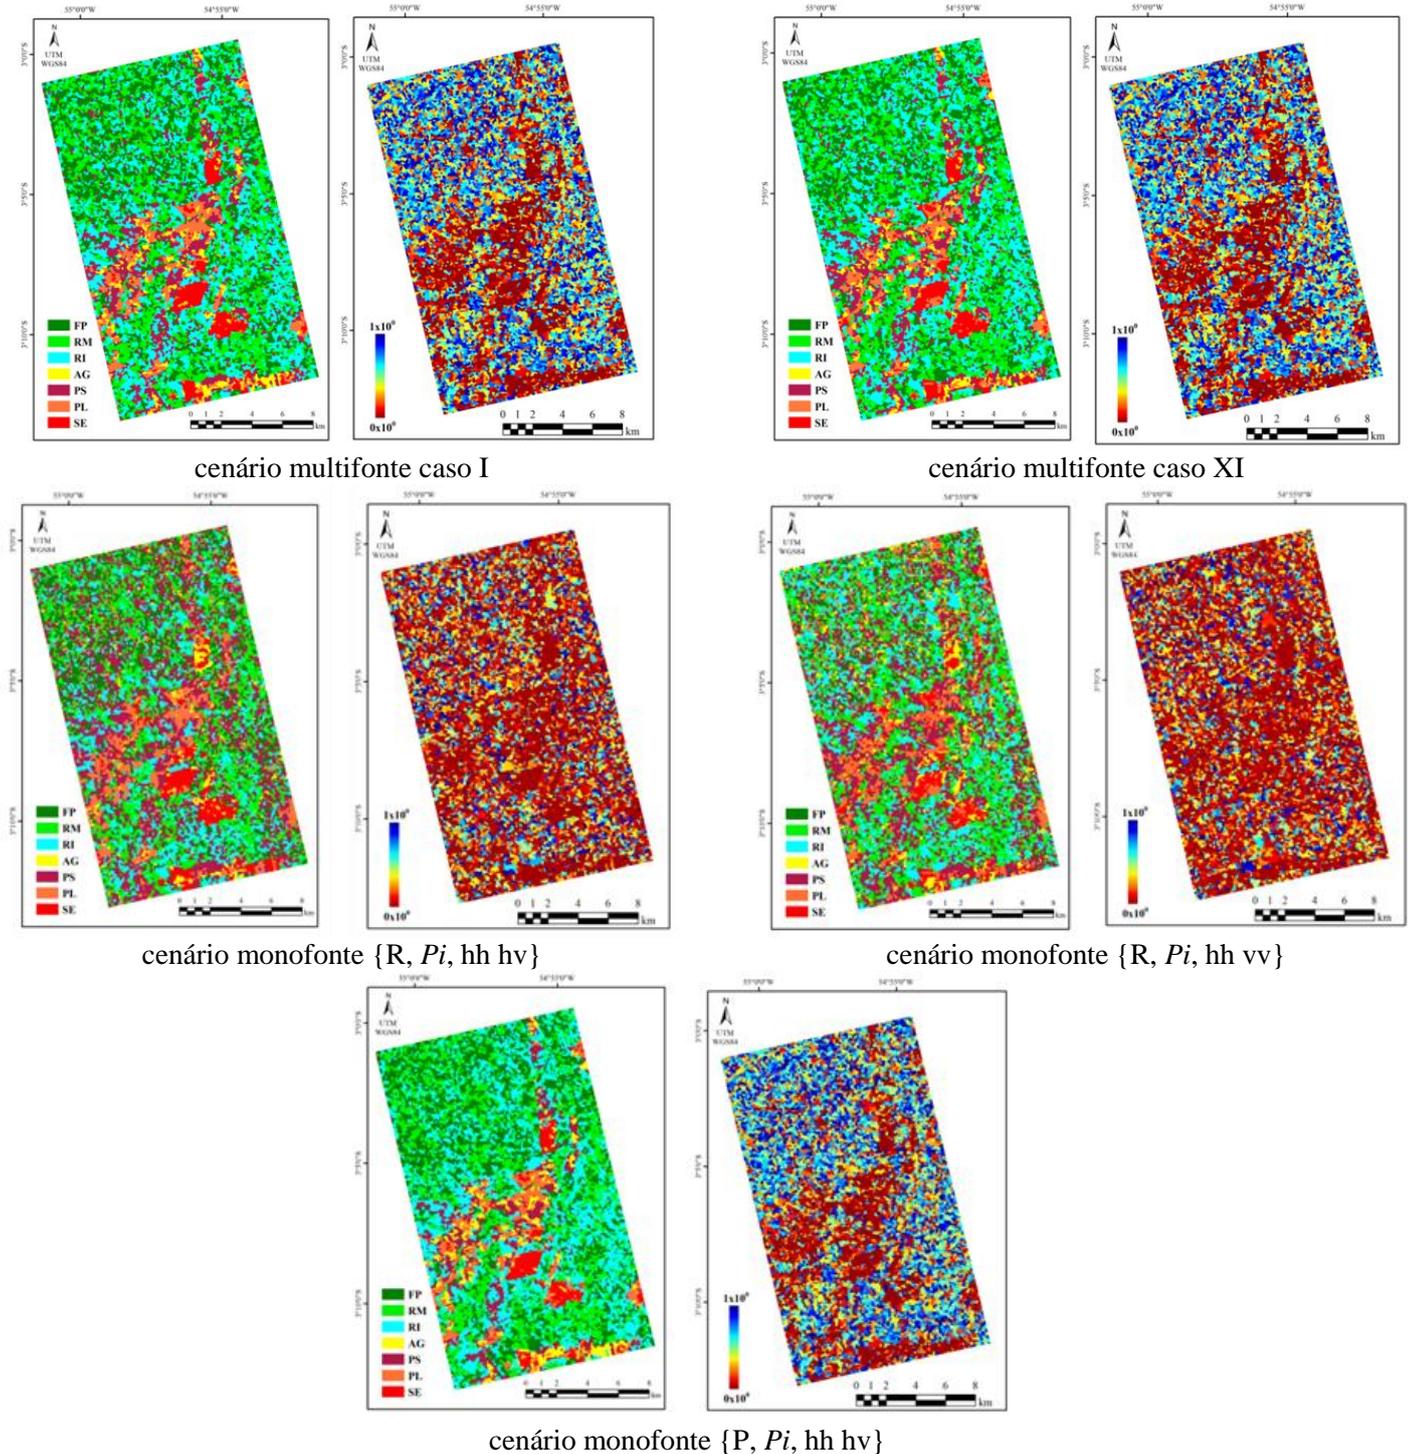


Figura 5. Cenários de classificações multifontes para os casos I e IX e cenários monofontes correspondentes.

A partir das classificações monofontes palar e radarsat, nota-se que a classe Floresta Primária é melhor identificada na banda L, assim como as classes Agricultura e Solo Exposto. Porém, a classe Pasto Sujo é mais bem classificada na banda C. A identificação das outras classes não sofre grandes alterações com a variação das bandas. Nas classificações multifontes relativas aos casos I e XI, é nítida a contribuição da imagem palar para identificação das classes Floresta Primária e Solo Exposto, e da imagem Radarsat para identificação da classe Pasto Sujo.

Nos mapas de confiabilidade, valores próximos a 1 (azul) indicam maior certeza e próximos a 0 menor certeza (vermelho). Na Figura 5 observa-se o aumento da certeza para

algumas classes ao aplicar-se a metodologia. Nos casos I e XI, por exemplo, no mapa de confiabilidade da classificação pulsar, nota-se maior certeza na identificação da classe Floresta Primária, o mesmo não ocorrendo para as classificações radarsat quando alterna-se a modelagem dos dados.

5. Considerações finais

Para os quatorze cenários multifontes construídos, dez exibiram resultados superiores àqueles obtidos pelas classificações individuais. Nos casos em que não houve melhorias aparentes, a imagem pulsar foi modelada pela distribuição Par de intensidades e a radarsat pela distribuição *Wishart*. Para os casos em que houve melhorias, ambas as imagens foram modeladas pela mesma distribuição. De acordo com os resultados, para a geração dos cenários multifontes dos mínimos entre imagens SAR aconselha-se manter a mesma modelagem para ambos os dados, seja ela por meio da distribuição Par de intensidades ou *Wishart*.

Vale ressaltar a importância da análise das acurácias e erros por classe, uma vez que, as melhorias nas classificações podem ser refletidas em classes específicas mesmo quando o índice de acurácia global não indicar melhorias aparentes. Para os casos IX e X, os índices de acurácia foram inferiores aos individuais, entretanto, ao analisar-se a acurácia por classes, notaram-se melhorias superiores a 40% e 100% relativas à classe Regeneração Inicial, nesta ordem, em relação às classificações pulsar e radarsat.

Os cenários multifontes com os maiores índices de acurácia correspondem aos casos I e XI onde ambas as imagens foram modeladas pela distribuição Par de intensidades. Os índices de acurácia apresentados por estes cenários resultaram em *QIC* superiores a 11% em relação a classificação pulsar e 26% em relação as classificações radarsat. Embora os casos I e XI tenham apresentado os mesmos coeficientes *kappas*, para a acurácia por classe, notou-se que no caso I, os maiores índices equivalem às classes Floresta Primária e Solo Exposto enquanto no caso XI representam às classes Floresta Primária e Regeneração Intermediária. Portanto, conclui-se que a técnica de “classificação multifonte” relativa ao cenário dos mínimos, aplicada à imagens SAR, pode melhorar os resultados individuais de classificação.

6. Agradecimentos

Os autores agradecem ao CNPq (Processo: 313153/2016-7) pelo suporte financeiro.

7. Referência bibliográficas

BRAGA, B.C.; FREITAS, C.C.; SANT'ANNA, S.J.S. Distâncias estocásticas e mapas de incertezas aplicados à classificação de dados de múltiplos sensores. **Revista Brasileira de Cartografia (RBC)**, v. 7, n. 67, p. 1391-1411, 2015a.

BRAGA, B. C.; FREITAS, C. C.; SANT'ANNA, S. J. S. Multisource classification based on uncertainty maps. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), Milan, Italy. **Proceedings...** 2015b. ISBN 9781479979295. doi: <10.1109/IGARSS.2015.7326508>.

BRAGA, B. C. **Distâncias estocásticas e testes de hipóteses associados aplicados à classificação de imagens provenientes de múltiplos sensores independentes**. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3M2MERE>>. Acesso em: 16 out. 2016.

PARADELLA, W.; A. Imagens de radar – fundamentação e experiência com o SAR na Amazônia. **Fator Gis 14** (Curitiba), v. 4, n. ju/jul. 1996, p. 40-41,1996.

SILVA, W.B. **Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas: aplicações a dados polarimétricos**. 2013. 143p. (sid.inpe.br/mtc-m19/2013/02.20.16-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DJMB48>>. Acesso em: 27 jul. 2016.