

Comparação do uso combinado de variáveis espectrais e índices de vegetação calculados a partir das bandas Red e Red Edge para classificação de uma imagem RapidEye

Carla Jaqueline Casaroti
Jorge Antonio Silva Centeno
Jaqueline Prunzel

Universidade Federal do Paraná – UFPR
Curso de Pós Graduação em Ciências Geodésicas
Caixa Postal 19001, CEP: 81.531-990, Curitiba, Paraná, Brasil
carlacasaroti@gmail.com, centeno@ufpr.br, jaquelineprunzel@gmail.com

Abstract. This paper consists on describing the steps involving two classifications, using the OBIA (Object-oriented Image Analysis) approach along with a RapidEye high spatial resolution image, in order to compare the classification accuracy using the usual red band and the red edge band, to classify the vegetation land cover. To classify the geographic objects yielded from the multiresolution segmentation, spectral descriptors from the bands and NDVI's (Normalized Difference Vegetation Index) from the usual band red and the band red edge, as well as a Digital Elevation Model (DEM) were used. To make the descriptors' choice, a selection was made towards the attributes, which could better separate the classes of interest regarding the samples. The two classifications were performed, using the selected descriptors to each one, and then the global accuracy as well as the coefficient Kappa and confusion matrix were compared. The global accuracy from the first classification using the usual red band was of 87% and the other one was 90%, indicating that, the red edge band could improve in 3% the classification accuracy when used. As main steps of the released methodology we had: classes of interest definition, choice of the segmentation parameters, class descriptors selection for the two classifications, and at last the two classifications.

Palavras-chave: Classification, NDVI, confusion matrix, object-based image analysis, classificação, NDVI, matriz de confusão, análise de imagens orientada a objeto.

1. Introdução

Com o desenvolvimento tecnológico dos sensores orbitais, as imagens advindas dessas plataformas melhoraram tanto no âmbito da resolução espacial, quanto na resolução espectral. Essas imagens podem ser utilizadas nas classificações da cobertura e uso do solo – como, por exemplo, para monitorar e mapear a vegetação.

Um exemplo de sensor orbital com alta resolução espacial e resolução multiespectral é a constelação de satélites *RapidEye* (5 plataformas no total para o imageamento), podendo chegar a 5 metros de resolução espacial, com 5 bandas espectrais. Estes sensores, além das bandas espectrais conhecidas convencionalmente (*Red, Green, Blue, Near InfraRed*), contêm a banda vermelha adicional *Red Edge*, localizada na região do espectro eletromagnético entre 690 a 730 nm, local onde ocorre uma mudança abrupta na reflectância da clorofila.

Em imagens ópticas de alta (de 5 a 1 metro) ou altíssima (abaixo de 1 metro) resolução espacial torna-se mais difícil separar tipos de cobertura da terra/solo, considerando apenas os valores digitais de cada pixel isoladamente (CARLEER E WOLFF, 2007), pois, o aumento da resolução espacial tem por consequência o aumento da variabilidade nos níveis digitais da imagem, sendo assim, métodos orientados ao objeto geográfico se fazem necessários nesse contexto de análise e processamento.

Considerando a classificação da cobertura vegetal do solo, muitos trabalhos tanto nos métodos de processamento baseado em pixel ou em objeto foram desenvolvidos. Em Wentao *et al* (2014), o objetivo do trabalho foi investigar a utilidade do uso de medidas de textura e outros atributos para classificação da cobertura vegetal, mais especificamente neste caso, em zonas úmidas – de várzea. A árvore de decisão QUEST (*Quick, Unbiased, Efficient, Statistical Tree*) foi aplicada para uma imagem da região de interesse – região na província de Qinghai, China. A base de dados utilizada para a classificação consistiu em: dados espectrais

das bandas, as componentes principais, medidas de textura baseadas em pixel, modelo digital de elevação (MDE) e dados anteriores de cobertura da área de pesquisa. As medidas de textura utilizadas escolhida neste trabalho foram baseadas nas oito medidas frequentemente usadas da GLCM (matriz de co-ocorrência). Os resultados mostraram que, variância, média e entropia foram efetivas na distinção de diferentes tipos de vegetação nas zonas úmidas da área de estudo. A acurácia global foi de 84,19% e o coeficiente *Kappa* foi de 0,8261. Os resultados indicaram que a introdução de medidas de textura podem melhorar a acurácia global em 12,05% e o coeficiente *Kappa* em até 0,1407 comparados aos resultados obtidos usando somente informações espectrais e dados auxiliares.

Em Dobrowski *et al* (2008), os autores usaram a análise de imagens baseada em objeto para mapear a composição da vegetação ao longo de uma bacia hidrográfica localizada na cadeia de montanha de Sierra Nevada (Califórnia, USA). Utilizaram fontes de dados extraídos de modelos de distribuição individual de espécies, dados espectrais das imagens Landsat e estimativas de cobertura derivadas de variáveis de textura advindas de imagens aéreas. Como resultado principal, 12 tipos de plantas foram mapeados com acurácia global de 75% e coeficiente *Kappa* de 0,69. Foi verificado que os modelos de distribuição individual de espécies melhoraram a acurácia do mapa em 15%, comparados aos mapas com apenas informações derivadas das imagens. Por fim, os resultados ressaltaram a importância das variáveis com informações de terreno e bioclimáticas quando se mapeia a vegetação em zonas acidentadas.

A fim de avaliar o potencial de imagens de alta resolução espacial na identificação de duas espécies de vegetação, na região do Alentejo (Portugal), Sousa *et al* (2010) realizaram um estudo de classificação a partir de uma imagem de alta resolução espacial do satélite *Quickbird*. A análise de imagens baseada em objeto foi utilizada na identificação de duas classes de vegetação predominantes, utilizou-se uma máscara com NDVI para filtrar a vegetação. Como conclusões, os autores obtiveram que a detecção, delineamento e identificação automática do coberto arbóreo com dados de sensoriamento remoto podem contribuir de maneira mais rápida e com menor custo. Os autores concluíram também que, apesar da baixa resolução espectral, a alta resolução espacial e a abordagem da análise de imagem orientada ao objeto geográfico garantiram o fator da espacial (forma), que foi importante nesse contexto.

Chowdhury *et al* (2015) tiveram como foco principal a identificação de áreas de vegetação em risco de incêndio ao lado de estradas. O trabalho apresenta uma nova técnica classificadora baseada em um novo descritor de textura – chamado de co-ocorrência de padrão binário (*Co-occurrence of Binary Pattern*). A metodologia se constituiu em cinco passos: pré-processamento, extração de atributos, treinamento com classificadores múltiplos, classificação, validação e análise estatística. O primeiro classificador foi baseado no SVM (*Support Vector Machine*), o segundo em FF-BPNN (*Feed Forward Back-Propagation Neural Network*) e o terceiro no Vizinheiro Mais Próximo (*k-NN – Nearest Network*), onde o algoritmo de “voto da maioria” (*Weighted Majority Voting*) foi utilizado para fundir os resultados dos três classificadores. Para análise e classificação, dois tipos de vegetação foram levados em conta nesse trabalho: densa e esparsa; como resultado final os autores obtiveram acurácia global foi de 92,72%, reforçando assim a importância e validade do método.

Um estudo feito na comparação das classificações com o uso da banda vermelha adicional (*red edge*) do satélite RapidEye foi feita por Souza *et al* (2015), onde os autores utilizaram de uma classificação baseada em pixel para analisar a performance do uso desta banda na discriminação dos diferentes tipos de vegetação definidos no trabalho, subdivididos em: pasto, cana de açúcar e floresta nativa. Os autores afirmam que a banda *Red Edge* foi mais sensível aos diferentes tipos de vegetação da área de estudo que a banda do infravermelho

próximo e que, diferentes combinações de bandas para os índices de vegetação ajudaram a distinguir e identificar as classes de interesse.

A partir do contexto abordado, o estudo realizado neste artigo consistiu em fazer uma comparação da influência do uso de dois tipos diferentes de banda vermelha na classificação da cobertura vegetal, utilizando uma análise de imagens baseada em objeto. Dessa maneira, o objetivo é comparar a acurácia global das classificações, quando do uso dos dados espectrais (bandas utilizadas do satélite); em um cenário se utilizava apenas a banda vermelha convencional e no outro se utilizava a banda *Red Edge*, fazendo também o uso do índice de vegetação da diferença normalizada (NDVI) calculado para as duas situações.

2. Material e Métodos

A área de estudo (figura 1) está localizada na parte sudoeste da bacia hidrográfica do reservatório do Capivari, localizado na Rodovia BR-116 (trecho Curitiba - São Paulo), no município de Campina Grande do Sul, a 50 km de Curitiba. O recorte da área de interesse foi selecionado por conter, predominantemente, cobertura vegetal. A imagem utilizada é advinda do satélite RapidEye, contendo a banda adicional do vermelho (*Red Edge*), datada do ano de 2015. Como dado adicional, também se obteve o Modelo Digital de Elevação (MDE) do terreno, que foi utilizado como banda de informação na classificação.

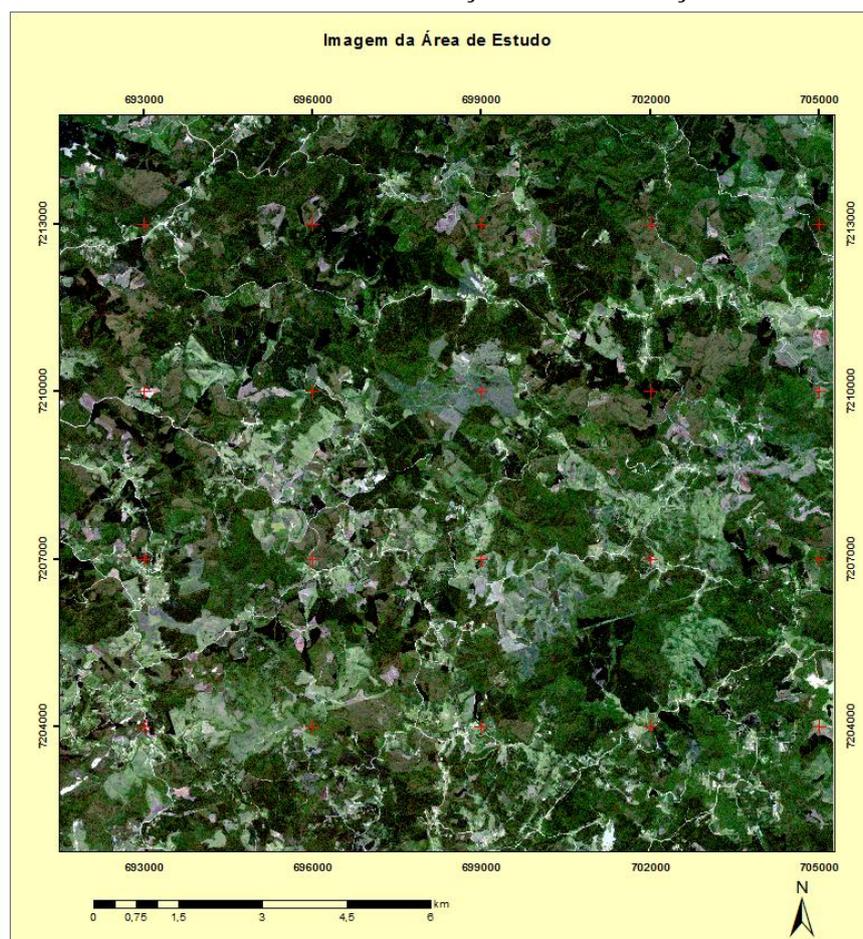


Figura 1 - Imagem da área de interesse

Como o interesse do estudo está focado na vegetação, o primeiro passo foi a definição das classes de interesse no processo de classificação baseada em objeto. Com observação e conhecimento prévio da área, as classes definidas foram: outros – contendo coberturas do solo como solo exposto e área impermeabilizada, vegetação alta tipo 1 – floresta com presença de

sombra, tendo variação de textura, vegetação alta tipo 2 – floresta não-sombreada, com textura mais áspera, vegetação alta tipo 3 – com textura mais suave que as anteriores, podendo representar as áreas de reflorestamento, vegetação baixa tipo 1 – vegetação baixa correspondente a áreas cultivadas, e vegetação baixa tipo 2 – delineando a vegetação de gramíneas/pasto.

A seguir, procedeu-se com a segmentação da imagem da área de estudo, utilizando o algoritmo FNEA (*Fractal Net Evolution Algorithm*) implementada no programa *eCognition* (*Definiens*). Os parâmetros de segmentação foram baseados na homogeneidade espectral e espacial da cena, tendo em conta que a imagem era predominantemente composta por cobertura vegetal. Mais detalhes sobre os parâmetros de segmentação e etapas envolvidas nesse contexto podem ser encontrados em Baatz e Schäpe (2001), Baatz e Schäpe (1999) e Blaschke *et al* (2000).

Com o nível de segmentação confeccionado, amostras das classes de interesse foram coletadas a fim de que se tivessem, tanto informações para a classificação pelo método do Vizinheiro mais Próximo (implementado no programa *eCognition*), quanto para a seleção dos descritores dessas classes. Tanto a segmentação, quanto as amostras de classes coletadas foram utilizadas nas duas classificações realizadas.

Após a segmentação, a classe “outros” foi separada das classes de vegetação em uma primeira etapa de classificação. Para isto, foi calculado o índice de vegetação NDVI (equação 1) e aplicado um limiar ao índice, considerando que a vegetação é caracterizada por valores altos do NDVI. O mesmo processo foi aplicado aos valores do NDVIe. Após esta separação ficaram apenas os segmentos das classes de vegetação na imagem.

Para estes segmentos foram calculados os dois índices de vegetação: no primeiro se faz o uso das bandas convencionais (*Red e NIR – near infrared*) como dados de entrada, do que resulta o conhecido NDVI (*Normalized Difference Vegetation Index*) calculado pela banda vermelha convencional, como mostra a equação 1). No segundo índice se faz o uso da banda vermelha adicional do satélite RapidEye, *Red Edge* no lugar da banda vermelha convencional, do que deriva um índice modificado NDVIe, conforme a equação 2.

$$NDVI = (NIR - RED)/(NIR+RED) \quad (1)$$

$$NDVIe = (NIR - REDe)/(NIR+REDe) \quad (2)$$

Onde

NIR: banda do infravermelho próximo

RED: banda do vermelho

REDe: banda do *red edge*

A definição dos descritores dos segmentos foi feita a partir desses dois conjuntos de dados. Esta definição se apoiou nos descritores que forneceram maior separabilidade entre as classes, em vista a escolher os atributos espectrais que menos se sobrepusessem na distribuição das amostras das classes de interesse, considerando as duas diferentes situações.

Para fins de comparação, procedeu-se à classificação dos dois conjuntos. As duas classificações da cobertura vegetal foram realizadas utilizando o método do Vizinheiro mais Próximo (*Nearest Neighbor*), que no caso do programa *eCognition* é efetuado utilizando-se das amostras coletadas para cada uma das diferentes classes para atribuir valores de funções de pertinência advindas da Lógica *Fuzzy*. Todas as etapas realizadas estão ilustradas e explicadas na seção a seguir, que contém os resultados do trabalho.

3. Experimentos

A segmentação multirresolução foi realizada criando-se um projeto para posterior classificação dos segmentos. Apenas um nível de segmentação foi utilizado, por atender as necessidades da finalidade da classificação, tendo com parâmetros: 100 para o parâmetro de escala, 0,1 para o parâmetro de forma e 0,5 para o parâmetro de compacidade.

No processo da classificação dos segmentos, primeiramente foi efetuada a separação dos segmentos que não pertenciam às coberturas vegetais observadas no contexto da cena. Uma classificação utilizando limiar foi realizada na classificação 1, seguindo a condição de que os segmentos com valores de NDVI (com banda vermelha convencional) menores que 0,27 foram alocados para a classe “outros”, e na classificação 2 com valores de NDVI (com banda *Red Edge*) menores que 0,18 foram alocados para a classe outros.

A segunda parte consistiu na coleta das amostras das classes de vegetação. As amostras coletadas foram as mesmas utilizadas nas duas classificações, alterando-se somente alguns dos descritores das classes. Abaixo estão listadas as combinações entre as classes de cobertura vegetal e os descritores espectrais que ofereceram sobreposição menor que 20% na distribuição das amostras das classes.

- Entre vegetação alta tipo1 e tipo 2: média do infravermelho próximo;
- Entre vegetação alta tipo 1 e tipo 3: média do infravermelho próximo e máxima diferença;
- Entre vegetação alta tipo 1 e vegetação baixa tipo 1: média do infravermelho, da banda *Red Edge*, e brilho;
- Entre vegetação alta tipo 1 e vegetação baixa tipo 2: média das bandas azul, verde, vermelha convencional, *Red Edge*, do MDE, dos NDVI's calculados com as duas bandas vermelhas, brilho e desvio-padrão da banda do NDVI calculado com a banda *Red Edge*;
- Entre vegetação alta tipo 2 e vegetação alta tipo 3: média do NDVI calculado com a banda *Red Edge* e máxima diferença;
- Entre vegetação alta tipo 2 e vegetação baixa tipo 1: média das banda do infravermelho próximo e *Red Edge* e brilho;
- Entre vegetação tipo 2 e vegetação baixa tipo 2: brilho, máxima diferença, desvio-padrão do MDE, médias das bandas, azul, verde, infravermelho próximo, vermelho, *Red Edge* e NDVI calculado com a banda *Red Edge*;
- Entre vegetação alta tipo 3 e vegetação baixa tipo 1: brilho, desvio-padrão do MDE, médias das bandas verde, infravermelho próximo, *Red Edge* e do NDVI calculado com a banda *Red Edge*;
- Entre vegetação alta tipo 3 e vegetação baixa tipo 2: brilho, máxima diferença, desvios-padrão das bandas azul e vermelha, médias das bandas azul, verde, infravermelho próximo, vermelho, *Red Edge*, e dos dois NDVI's;
- Entre vegetação baixa tipo 1 e 2: máxima diferença, média das bandas azul, verde, vermelho, e dos dois NDVI's.

Baseando-se nos resultados obtidos da comparação entre as classes e dos descritores que melhor as separavam, observou-se que os melhores descritores para diferenciar os tipos de vegetação alta foram: a média da banda do infravermelho próximo, a máxima diferença, o brilho, a banda *Red Edge*, e o NDVIe calculado com a banda *Red Edge*.

Para diferenciar as classes dos tipos de vegetação baixa, os melhores descritores foram: as médias da banda do azul, do verde, do vermelho convencional, dos NDVI e NDVIe, bem como a máxima diferença.

Para a separação dos tipos de vegetação alta e dos tipos de vegetação baixa, os melhores descritores foram: a média da banda do infravermelho próximo, média e desvio-padrão da banda vermelha convencional e média da banda *Red Edge*, brilho, média e desvio-padrão da

banda azul, média da banda verde, média e desvio-padrão do MDE, média dos dois NDVI's, bem como o desvio-padrão do NDVIe e a máxima diferença.

A análise preliminar serviu de base para a seleção de dois conjuntos de descritores para a classificação dos tipos de vegetação. Dois cenários foram considerados: a primeira classificação baseou-se em utilizar apenas a banda vermelha convencional na composição das cinco bandas de entrada. Na segunda classificação a banda *Red Edge* foi utilizada em lugar da banda vermelha. Assim Os conjuntos de descritores para cada uma das classificações, utilizando método do Vizinho Mais Próximo, foram:

- Classificação 1 – banda vermelha: brilho, médias das bandas azul, verde, vermelha, infravermelho próximo, do NDVI e do MDE, desvios-padrão das bandas azul e vermelha, e máxima diferença;
- Classificação 2 – banda *Red Edge*: brilho, média das bandas do NDVI (calculado com *Red Edge*), do infravermelho próximo, da verde, da azul, da *Red Edge*, do MDE, desvios-padrão do NDVI (calculado com *Red Edge*), da banda azul, da *Red Edge* e máxima diferença.

Pode se perceber que na segunda classificação, com a mudança das bandas vermelhas (convencional e *Red Edge*), ocorreu a adição do desvio-padrão do NDVIe calculado com a banda *Red Edge*, no entanto os descritores permaneceram os mesmos para as duas classificações. As imagens temáticas obtidas para cada caso estão apresentadas na figura 2.

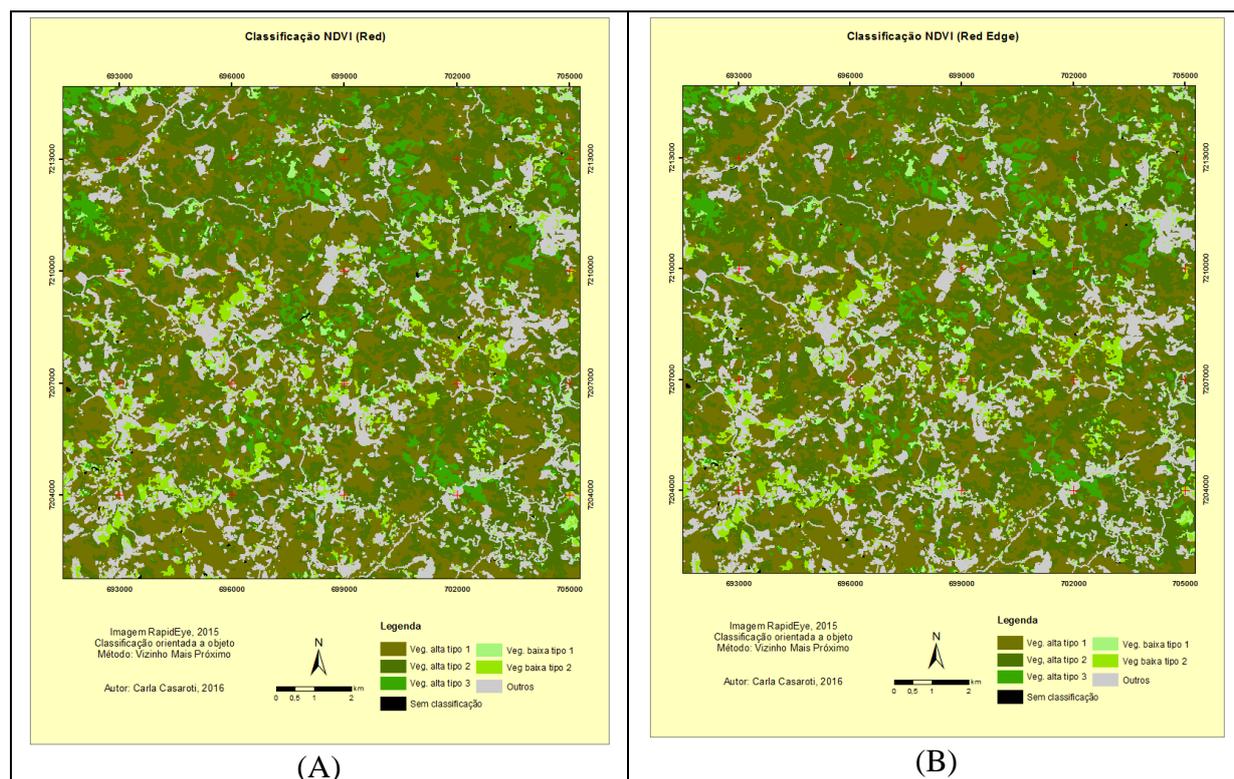


Figura 2 - Resultados das classificações, (A) classificação 1 e (B) classificação 2

Para avaliar a qualidade destas imagens temáticas, 10 amostras de cada classe foram coletadas como áreas de verificação. A tabela 1 contém os resultados da matriz de confusão da classificação 1 e a tabela 2 contém a matriz de confusão da segunda classificação.

Tabela 1 - Matriz de confusão da classificação 1

Classe\Amostra	A	B	C	D	E	F	Soma
Veg. Alta tipo 1 (A)	10	1	0	0	0	0	11
Veg. Alta tipo 2 (B)	0	6	0	0	0	0	6
Veg. Alta tipo 3 (C)	0	3	9	0	0	0	12
Veg. Baixa tipo 1 (D)	0	0	1	7	0	0	8
Veg. Baixa tipo 2 (E)	0	0	0	3	10	0	13
Outras (F)	0	0	0	0	0	10	10
Soma	10	10	10	10	10	10	

Com base na matriz de confusão da primeira classificação se pode conferir que houve confusão entre vegetação alta do tipo 2 com vegetação alta do tipo 1 e 3. Percebeu-se também confusão entre as classes vegetação baixa do tipo 1 com a do tipo 2, bem como vegetação baixa do tipo 1 com vegetação alta do tipo 3.

Tabela 2 - Matriz de confusão da classificação 2

Classe\Amostra	A	B	C	D	E	F	Soma
Veg. Alta tipo 1 (A)	9	1	0	0	0	0	10
Veg. Alta tipo 2 (B)	1	9	2	0	0	0	12
Veg. Alta tipo 3 (C)	0	0	8	0	0	0	8
Veg. Baixa tipo 1 (D)	0	0	0	10	2	0	12
Veg. Baixa tipo 2 (E)	0	0	0	0	8	0	8
Outras (F)	0	0	0	0	0	10	10
Soma	10	10	10	10	10	10	

Com a tabela da matriz de confusão da segunda classificação se observou, a partir das amostras de verificação, que vegetações altas e baixas se confundiram, mas apenas entre elas mesmas. Sendo elas: vegetação alta tipo 1 com vegetação alta tipo 2 e mutuamente, bem como vegetação alta tipo 3 e tipo 2; e vegetação baixa tipo 1 com vegetação baixa tipo 2.

A acurácia global e o coeficiente *Kappa* na primeira classificação foram de 87% e 0,84, respectivamente. Na segunda classificação a acurácia global foi de 90%, 3% maior que a primeira; e o coeficiente *Kappa* de 0,88.

3. Conclusões

Com os resultados obtidos das duas classificações realizadas neste artigo, pode-se afirmar que o uso da banda *Red Edge* na classificação dos objetos da imagem segmentada, utilizando uma abordagem baseada em objetos, melhora no contexto de classificação da cobertura vegetal da cena.

Com base nos descritores de classe escolhidos, algumas observações podem ser enfatizadas, para a separação dos tipos de vegetação alta e baixa, o modelo digital de elevação, a média da banda *Red Edge* e da banda vermelha, bem como seus respectivos índices de vegetação calculados, apareceram como bons descritores. Porém na primeira classificação, a vegetação baixa tipo 1 confundiu-se com vegetação alta tipo 3, Entre tanto, isto não ocorreu na segunda classificação utilizando a banda *Red Edge* e seu respectivo NDVIe.

O uso da banda vermelha adicional (*Red Edge*) conferiu melhor acurácia da classificação, bem como facilitou a separação entre as classes de vegetação alta e baixa, o que não

aconteceu quando se utilizou a banda vermelha convencional. Pelas acurácias globais das duas classificações, verificou-se que o uso somente da banda vermelha adicional pode melhorar em 3% a acurácia global da classificação e diminuir a confusão entre vegetação alta e baixa.

4. Agradecimentos

Os autores gostariam de expressar seus agradecimentos ao *Institut für Wasser und Gewässerentwicklung, Bereich Siedlungswasser – und Wassergüterwirtschaft* pela obtenção e concessão das imagens através da RESA (*RapidEye Science Archive*) - Alemanha.

5. Referências

- Baatz, M. & Schäpe, A. Multiresolution Segmentation: an optimization approach for high quality multiscale image segmentation. **Angewandte Geographische Informationsverarbeitung**, p.12-23, 2001.
- Baatz, M & Schäpe, A. Object oriented and multiscale image analysis in semantic network. 2nd International Symposium on operational Remote Sensing. ITC. Netherlands. 1999. Anais.
- Blaschke, T, Lang, S, Lorup, E, Strobl, J & Zeil, P. Objected oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. **Environmental information for planning**, v. 2. Metropolis Verlag. 2000.
- Carleer, A. & Wolff, E. Change detection for updates of vector database through region-based classification of VHR satellite data. SPIE Remote Sensing Europe, 72. September 17-21, 2007, Florence, Italy. Proceedings of SPIE 6749. v. 6749, p. 674911-1-10. 2007.
- Dobrowski, S. Z.; Safford, H. D.; Cheng, Y. B.; Ustin, S. L. Mapping mountain vegetation using species distribution modeling image-based texture analysis, and object-based classification. **Applied Vegetation Science**; v. 11 n. 4, p. 499-508, 2008.
- Chowdhury, S.; Verma, B.; Stockwell, D. A novel texture feature based multiple classifier technique for roadside vegetation classification. **Expert Systems with Applications**, v. 42, p. 5047-5055, 2015.
- Sousa, A. M. O.; Mesquita, P.; Gonçalves, A. C.; da Silva, J. R. M. Segmentação e classificação de tipologias florestais a partir e imagens QUICKBIRD. **Revista Ambiente**, v. 6, ed. Especial, p. 57-66, 2010.
- Souza, C. H. W.; Lamparelli, R. A. C.; Justina, D. D. D.; Rocha, J. V. Estudo da Banda Red Edge do Satélite na discriminação da cobertura vegetal. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2015, João Pessoa-PB. **Anais**. São José dos Campos: INPE, 2015. Artigos, p. 3612-3618. Disponível em: <<http://www.dsr.inpe.br/sbsr2015/files/p0713.pdf>>. Acesso em outubro de 2016.
- Wentao, Z.; Bingfang, W.; Hongbo, J.; Hua, L. Texture classification of vegetation cover in high altitude wetlands zone. In 35th Symposium on Remote Sensing of Environment (ISRE35), 2014, Beijing. IOP Conf. Series and Environmental Science 17. DOI: 10.1088/1755-1315/17/1/012083.