

## ANÁLISE DE DIFERENTES TÉCNICAS DE CLASSIFICAÇÃO DIGITAL NO MAPEAMENTO DO USO E COBERTURA DA TERRA

G. V. TREVISAN<sup>1</sup>; P. C. BISPO<sup>2</sup>; A. L. S. MAIA<sup>3</sup>

**RESUMO.** O objetivo deste trabalho foi avaliar o desempenho de diferentes técnicas de classificação no mapeamento de classes de uso e cobertura da terra sobre três tipos de entrada de dados – bandas originais, equalizadas e frações do modelo linear de mistura espectral. Quatro classificações foram testadas: K-médias, Iseseg, Máxima Verossimilhança e Battacharya. Os diferentes métodos de classificação foram eficientes no mapeamento com desempenho muito bom de acordo com o coeficiente Kappa. Não houve diferença expressiva no desempenho global dos algoritmos em função do tipo de entrada de dados. Em qualquer entrada de dados as classes floresta, floresta secundária e solo exposto foram bem discriminados pelos algoritmos de Máxima Verossimilhança, K-médias e Battacharya respectivamente. A classe pasto foi mais bem reconhecida pelo Iseseg sobre as bandas originais.

**PALAVRAS-CHAVE:** técnicas de classificação, pré-processamento, desempenho global e condicional.

## ANALYSIS OF DIFFERENT DIGITAL CLASSIFICATION SCHEMES TO MAPPING LAND USE AND COVER

**ABSTRACT.** The purpose of this work was to evaluate the effect of using several image classification schemes for mapping land cover and use in three input data: original bands, equalization of bands, fractions of linear mixture model. Four classification procedures were used: K-means, Iseseg, Maximum Likelihood and Battacharya. Results showed that all classification methods used were efficient with very good performance according to the Kappa coefficient. There were not expressive differences in the algorithms global performance with the variation in input data. For any data input the class forest, secondary forest and soil were well discriminate with MaxVer, K-means and Battacharya respectively. The class grass was well recognized on original bands with Iseseg.

**KEYWORDS:** classification schemes, preprocessing, global and conditional performance.

---

<sup>1</sup> Bióloga, doutoranda em sensoriamento remoto, Instituto Nacional de Pesquisas Espaciais - INPE. Av. dos Astronautas, 1758. Jardim da Granja. CEP 12227-001. São José dos Campos, SP, Brasil. tel.: (12) 3945-6458. fax: (12)3945-6449. email: [giselle@dsr.inpe.br](mailto:giselle@dsr.inpe.br)

<sup>2</sup> Bióloga, doutoranda em sensoriamento remoto, INPE.

<sup>3</sup> Engenheiro ambiental, mestrando em sensoriamento remoto, INPE.

## **INTRODUÇÃO**

O reconhecimento e a quantificação do uso e cobertura da terra através do sensoriamento remoto tem sido alvo de muitos estudos na Amazônia, onde a dimensão territorial não poderia ser monitorada facilmente sem este recurso (Skole e Tucker, 1993; Moran *et al.*, 1994; Alves *et al.*, 1998; Alves *et al.*, 2003). Diferentes metodologias de classificação de imagens digitais têm sido utilizadas para esse fim, resultando, por vezes, em diferentes índices de uso e cobertura da terra dentro de uma mesma área. A manipulação das imagens de entrada por meio de transformações espectrais também pode gerar variações neste processo.

A investigação do mapeamento através da análise do desempenho do classificador poderia evidenciar as variações que cada algoritmo atribui sobre as feições analisadas e assim auxiliar na escolha do processo metodológico. Neste contexto, o presente trabalho tem como objetivo analisar se há diferença no desempenho de quatro técnicas de classificação digital na caracterização de feições do uso e cobertura da terra: floresta, floresta secundária, solo exposto e pasto; e se a performance dos algoritmos varia com diferentes tipos de pré-processamentos.

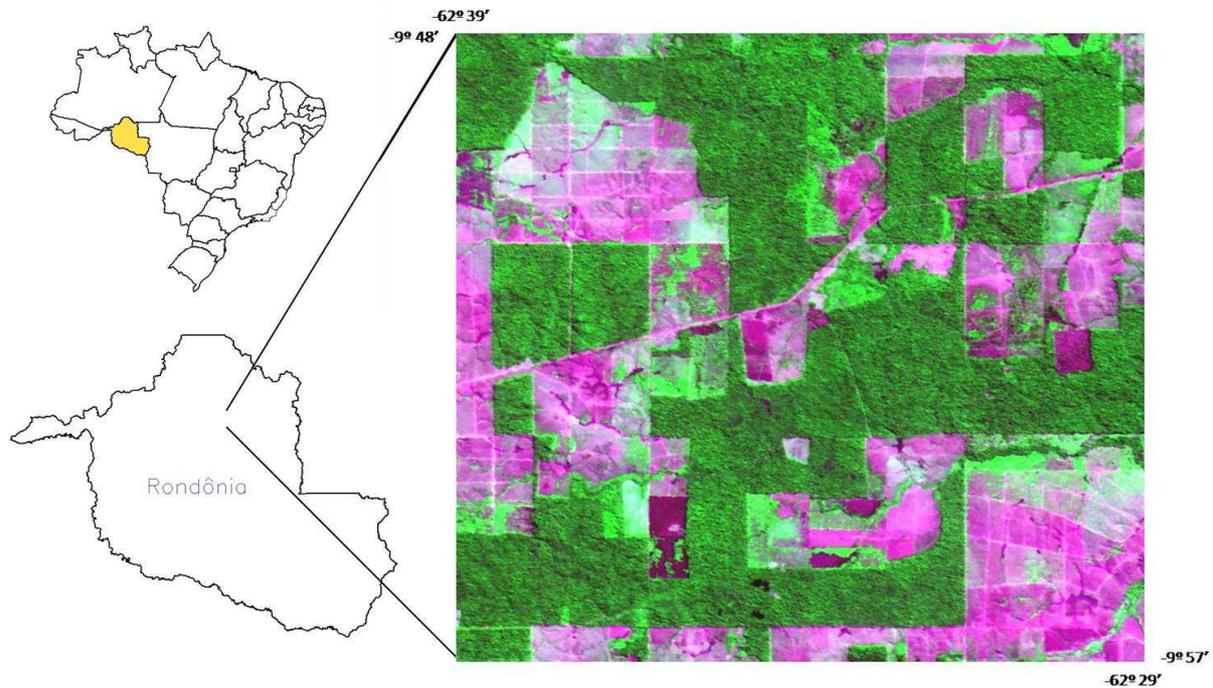
## **MATERIAL E MÉTODOS**

A área de estudo inclui parte do município de Ariquemes no estado de Rondônia (Figura 1). O clima predominante da região é tropical úmido com estação seca bem definida entre junho e agosto, tipo Aw pela classificação de Köppen. O relevo na área de estudo é suave ondulado e a fisionomia vegetacional característica é a floresta ombrófila densa ou aberta (RADAMBRASIL, 1978). Esta região é caracterizada pela ocupação de propriedades de médio (1.000 ha) e pequeno (25-100 ha) porte, onde diferentes tipos de culturas, de gramíneas e de manejo dos pastos compõem um mosaico relativamente complexo de padrões de uso e cobertura da terra (Alves *et al.*, 1998, Alves *et al.*, 1999).

A caracterização do uso e cobertura da terra foi realizada em um recorte da imagem CCD/CBERS-2 (órbita/ponto 174/111) de junho de 2004, compreendendo uma área de 286,77 km<sup>2</sup> (Figura 1). Uma imagem do sensor TM do satélite Landsat georreferenciada (231/67) do ano 2000 (disponibilizada por Alves *et al.*, 2003) foi utilizada como referência no registro (modelo polinomial de 1º grau).

Foram empregadas como dados de entrada: (1) bandas originais, (2) imagens ajustadas por meio de equalização da média e variância entre bandas e (3) imagens fração provenientes do modelo linear de

mistura espectral; e utilizadas as classificações supervisionadas: (1) Máxima Verossimilhança, (2) Battacharya; e as não supervisionadas: (3) K-médias e (4) Isoseg.



**Figura 1.** Área de estudo. Município de Ariquemes, RO. Composição R5G4B3.

O Modelo Linear de Mistura Espectral (MLME, Shimabukuro e Smith, 1991) considera que o valor do pixel em qualquer banda espectral é a combinação linear da resposta de cada componente dentro do pixel e tem como objetivo reduzir a mistura, quantificando as proporções de elementos puros que constituem o pixel misturado (Freitas e Cruz, 2005). O MLME foi aplicado sobre as bandas originais e geradas as imagens frações sombra, vegetação e solo:

$$r_1 = a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n + e_1$$

$$r_2 = a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n + e_2$$

...

$$r_i = a_{m1} x_1 + a_{m2} x_2 + \dots + a_{2n} x_n + e_m$$

Onde,  $r_i$ : reflectância espectral na  $i$ ésima banda espectral de um pixel;  $a_{ij}$ : reflectância espectral conhecida do  $j$ ésimo componente na  $i$ ésima banda espectral;  $x_j$ : valor a ser estimado de proporção do  $j$ ésimo componente dentro do pixel;  $e_i$ : erro de estimação para a  $i$ ésima banda espectral.

A escolha do pixel puro (endmember) para ser implementado no modelo deve ser um processo acurado. Nesta etapa os componentes puros foram inicialmente agrupados através da análise do diagrama de

espalhamento 3-D (bandas 3, 4 e 5) e selecionados a partir do exame minucioso de suas respectivas respostas espectrais em todas as bandas utilizadas no estudo.

Para o ajuste de média e variância entre as bandas foi estabelecida à média final em 128 para que as bandas apresentassem brilho intermediário. Diferentes valores de variância final foram testados, sendo escolhido 180 por este não causar saturação (overflow) com a média estabelecida. O ajuste foi realizado através da linguagem de programação LEGAL implementado no software SPRING 4.2.

No processo de classificação foram discriminadas quatro feições de uso e cobertura da terra: (1) floresta primária, (2) floresta secundária, (3) pastagem e (4) solo exposto.

Classificações não supervisionadas:

- 1- K-médias. Foram estabelecidos 10 iterações e 9 temas correspondentes à subdivisão das feições de uso e cobertura supracitadas. Este critério foi utilizado para diminuir a confusão entre classes que apresentam grande variedade de distribuição de níveis de cinza.
- 2- Iseseg. A segmentação foi realizada pelo método de crescimento de regiões com limiar de similaridade 8 e área 10. Este limiar foi estabelecido com base em trabalhos realizados na área de estudo (Alves et al., 1998). O limiar de aceitação do algoritmo de classificação foi definido em 99,9% para que a comparação entre os diferentes tipos de classificações fosse compatível, visto que limiares menores deixavam áreas não classificadas.

Classificações supervisionadas:

- 3- Máxima Verossimilhança. O limiar de aceitação foi estabelecido em 99,9% e as amostras de treinamento foram adquiridas através da análise do mapa de referência gerado por interpretação visual e pela análise da resposta espectral das classes nas diferentes bandas.
- 4- Battacharya. A segmentação utilizada foi à mesma realizada para o classificador Iseseg. O limiar de aceitação foi definido em 99,9% e as amostras de treinamento foram às mesmas adquiridas para o algoritmo de máxima verossimilhança.

A produção do mapa de referência foi realizada através de interpretação visual por intermédio da ferramenta edição matricial para o modelo temático implementada no SPRING.

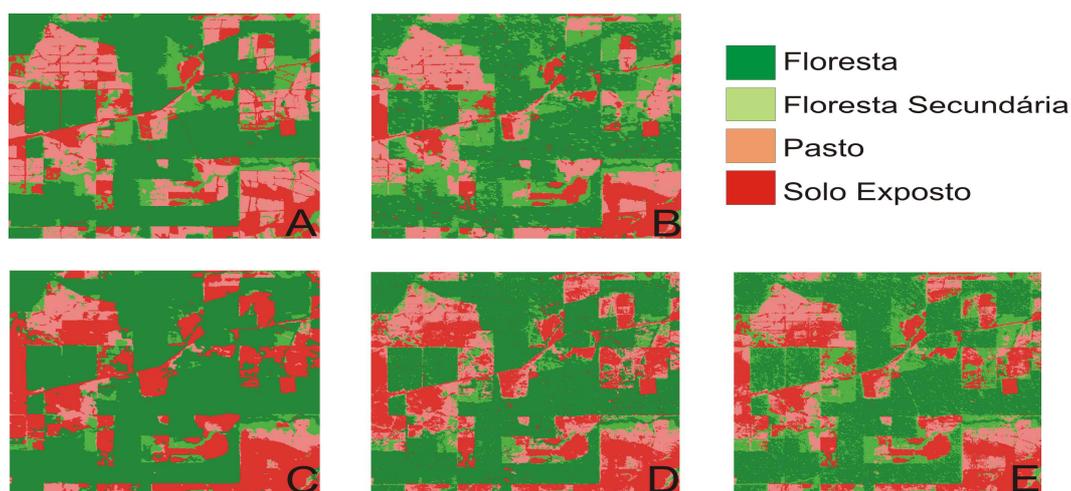
Para quantificar os erros gerados pelas diferentes técnicas de classificação utilizadas neste estudo, foram construídas as matrizes de erro ou de confusão, que permitem a comparação entre os dados provenientes das amostras de validação e o resultado da classificação. A partir destes dados foi calculada a exatidão global ou acurácia do mapeamento e condicional (por classes), por meio do coeficiente Kappa (K). Esta análise é uma técnica multivariada discreta usada no estabelecimento da acurácia para determinar estatisticamente se os resultados gerados são significativamente diferentes

(Colgaton e Green, 1999). Uma das vantagens assumida pelo Kappa é de que ele incorpora as informações dos pixels mal classificados, dos classificados e dos não classificados. Os ranges de acerto foram estabelecidos segundo Landis e Koch (1977) como:

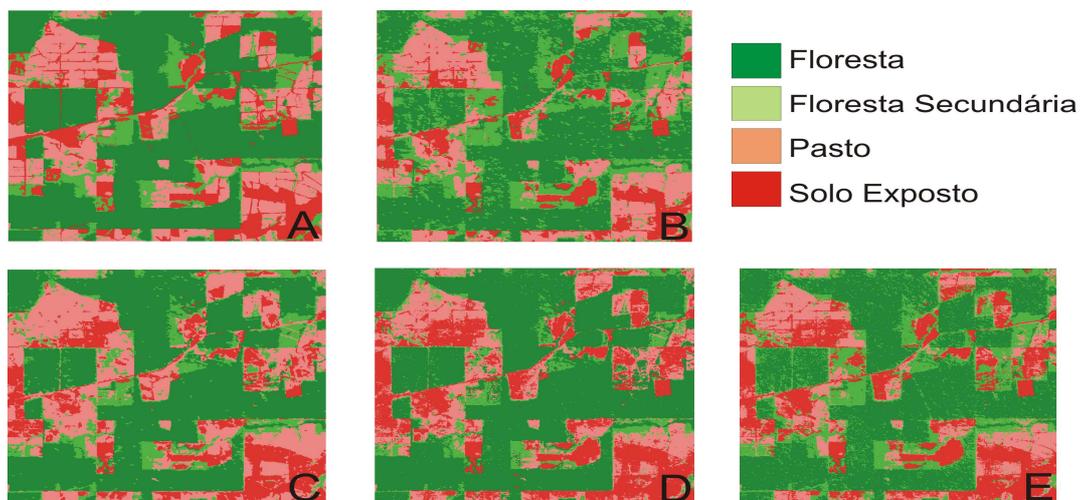
Kappa	Desempenho da Classificação
$< 0$	Péssimo
$0 < k < 0,2$	Mau
$0,2 < k < 0,4$	Razoável
$0,4 < k < 0,6$	Bom
$0,6 < k < 0,8$	Muito Bom
$0,8 < k < 1,0$	Excelente

## RESULTADOS E DISCUSSÃO

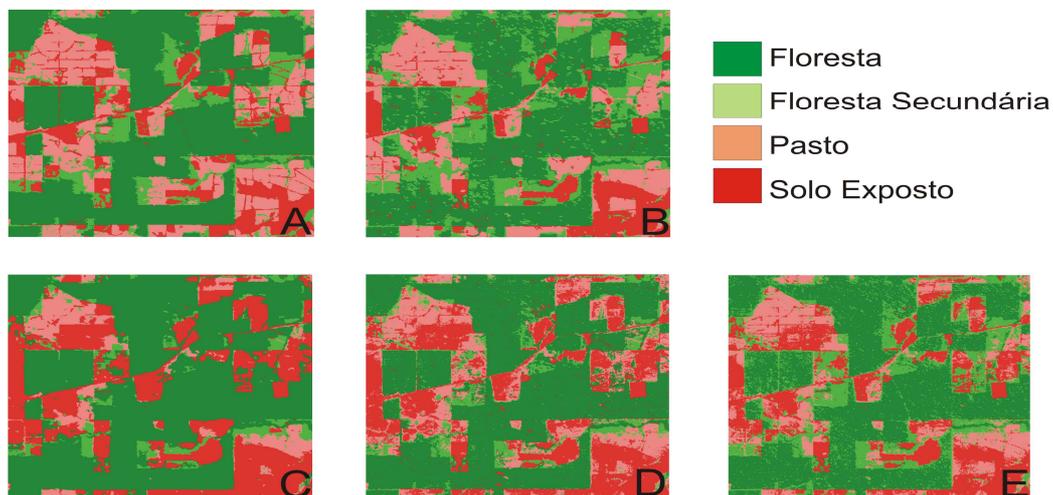
A análise visual dos mapas temáticos permitiu averiguar o desempenho dos classificadores sobre as feições estudadas nos diferentes tipos de entrada de dados (Figura 2, 3 e 4). O classificador Iseg reduziu o número de pixels isolados nos mapas produzidos sobre as bandas originais e sobre as do MLME, mas só se mostrou eficaz no reconhecimento da classe pasto e floresta secundária (Figura 5). Ao contrário, os algoritmos Battacharya e o MaxVer produziram muitos pixels isolados da classe floresta secundária. O baixo Kappa condicional (Kc) desta feição, para estes classificadores, demonstra esta confusão (Figura 5). A classificação pelo K-médias também compôs um produto com muitos pixels isolados da classe solo exposto, no qual pode ser averiguado baixo Kc (Figura 5).



**Figura 2.** Processamento sobre as bandas originais. a) Mapa de referência, (b) Battacharya, (c) Iseg, (d) K-médias e (e) MaxVer.



**Figura 3.** Processamento sobre as bandas com ajuste de média e variância. a) Mapa de referência, (b) Battacharya, (c) Iseseg, (d) K-médias e (e) MaxVer.

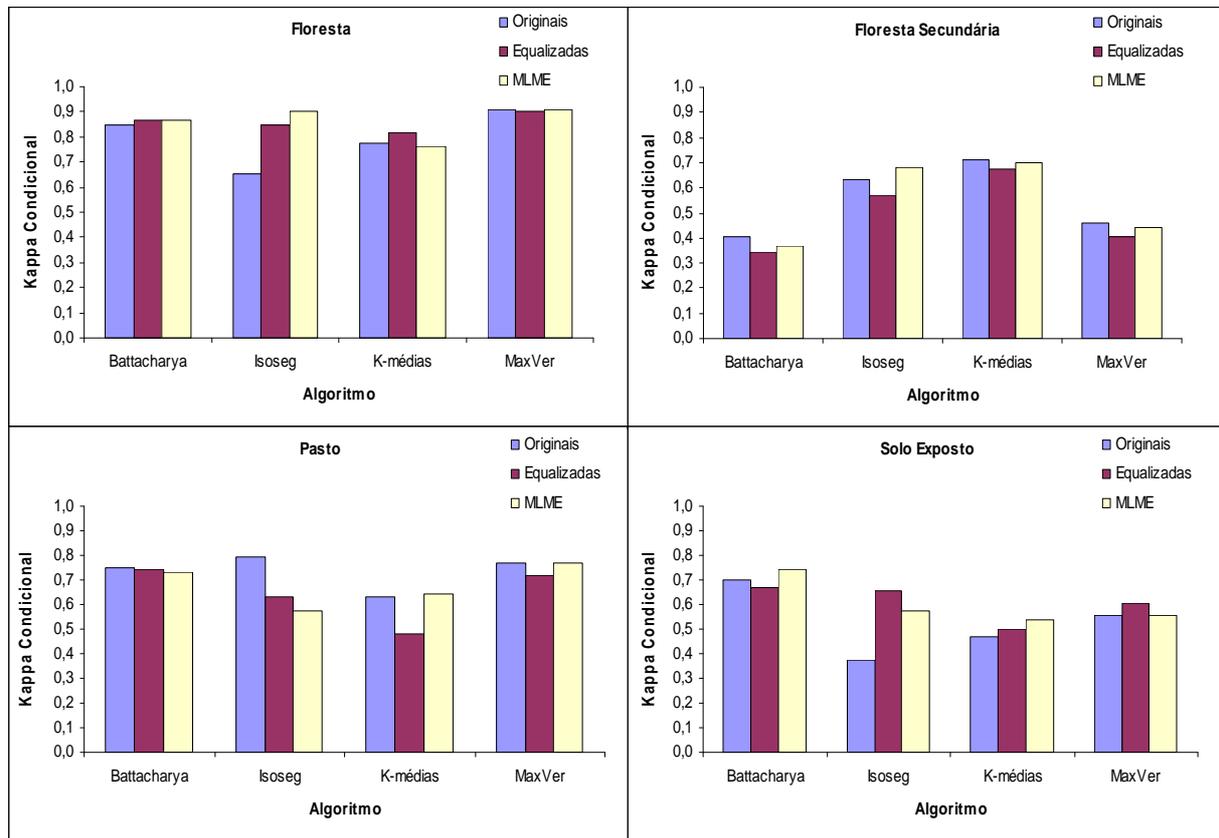


**Figura 4.** Processamento sobre as bandas vegetação, solo e sombra, geradas pelo modelo de mistura. a) Mapa de referência, (b) Battacharya, (c) Iseseg, (d) K-médias e (e) MaxVer.

A confusão entre as classes de mapeamento, causada pelos erros de inclusão ou omissão nas diferentes técnicas de classificação, constituem num dos fatores que levam a diferentes estimativas da proporção de área ocupada por essas classes. Por exemplo, em áreas de capoeira em estágios avançados de sucessão secundária, o comportamento espectral é muito semelhante ao das florestas maduras, tornando-se uma tarefa difícil a separação entre elas. A acurácia individual de cada classe no processo de classificação é essencial para maior precisão sobre os resultados, principalmente se o usuário possui interesse em uma feição específica.

Em todos os processamentos analisados o algoritmo de Máxima Verossimilhança (Max Ver) discriminou mais precisamente a classe floresta, o K-médias obteve melhor discernimento da classe floresta secundária

e o Battacharya foi mais acurado na distinção da classe solo exposto (Tabela 1 - em negrito, Figura 5). A discriminação da classe pasto variou entre os pré-processamentos, sendo mais bem reconhecida pelo Isoseg sobre as bandas originais (0,8). A floresta foi à feição que obteve melhor desempenho (excelente) para qualquer entrada de dados ( $K_c > 0,9$ ).



**Figura 5.** Valores de Kappa Condicional para as diferentes feições analisadas nas quatro classificações estudadas nos três tipos de entrada de dados (originais, equalizadas e MLME).

Estes resultados mostram que, dependendo do alvo de interesse do usuário, um determinado algoritmo de classificação será mais preciso na discriminação do mesmo, e que a análise global do desempenho (Kappa global - Tabela 2) não significa maior acurácia no discernimento entre as classes.

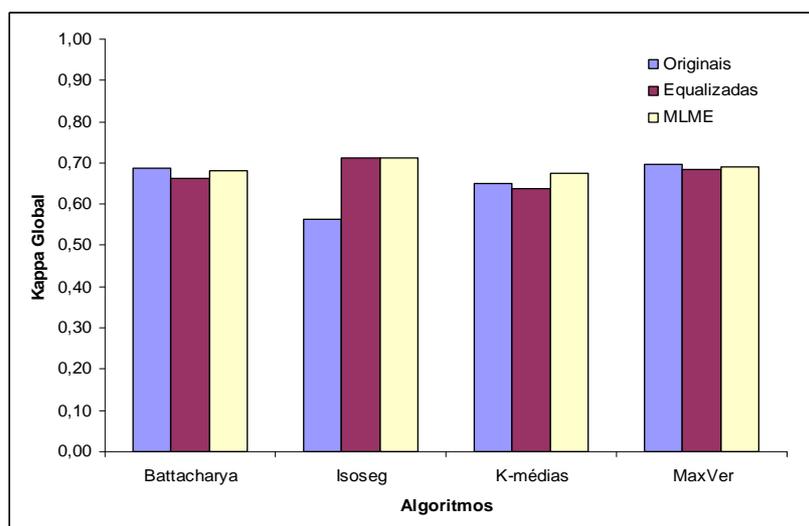
Não houve diferença expressiva no desempenho global dos algoritmos em função do tipo de entrada de dados (Figura 6). Com exceção da baixa performance do Isoseg sobre as bandas originais ( $K_g=0,56$ ), todos foram inclusos no range ‘muito bom’ segundo Landis e Koch (1977).

O algoritmo MaxVer apresentou o melhor desempenho global sobre as bandas originais, enquanto os mapas mais bem classificados, quando na entrada dos dados ajustados ou transformados pelo MLME, foram mapeados pelo algoritmo Isoseg (Tabela 2, em negrito). A equalização dos parâmetros através do

ajuste da média e variância proveu menor variabilidade (0,04) no desempenho dos algoritmos sobre os dados ajustados em comparação àqueles MLME transformados (0,07) ou ainda sobre as bandas originais (0,13).

**Tabela 1.** Kappa Condicional ( $K_c$ ) e sua variância (Var) nas diferentes classificações para os variados tipos de pré-processamento. F: floresta; P: pasto; F.S.: floresta secundária; S.E.: solo exposto.

Algoritmo	Classes	Originais		Ajustadas		MLME	
		$K_c$	Var	$K_c$	Var	$K_c$	Var
Battacharya	F	0,85	7 E-07	0,86	6,7 E-07	0,87	6,7 E-07
	P	0,75	1,7 E-06	0,73	1,7 E-06	<b>0,75</b>	1,8 E-06
	F.S	0,40	1,8 E-06	0,37	1,6 E-06	0,34	1,5 E-06
	S.E	<b>0,70</b>	2,5 E-06	<b>0,74</b>	2,5 E-06	<b>0,67</b>	2,6 E-06
Isoseg	F	0,65	9,3 E-07	0,90	4,7 E-07	0,84	6,7 E-07
	P	<b>0,80</b>	3,6 E-06	0,57	1,6 E-06	0,63	1,5 E-06
	F.S	0,63	7,2 E-06	0,68	3 E-06	0,57	3,8 E-06
	S.E	0,37	1,2 E-06	0,57	2,8 E-06	0,66	2,8 E-06
K-médias	F	0,78	8,3 E-07	0,76	8,4 E-07	0,82	7,5 E-07
	P	0,63	2,3 E-06	0,64	2 E-06	0,48	1,4 E-06
	F.S	<b>0,71</b>	5,1 E-06	<b>0,70</b>	4,6 E-06	<b>0,67</b>	5,1 E-06
	S.E	0,47	1,6 E-06	0,54	2,1 E-06	0,50	3,6 E-06
MaxVer	F	<b>0,91</b>	4,7 E-07	<b>0,91</b>	4,7 E-07	<b>0,90</b>	5,1 E-07
	P	0,77	1,9 E-06	<b>0,77</b>	1,9 E-06	0,72	1,8 E-06
	F.S	0,46	2,1 E-06	0,44	2 E-06	0,40	1,9 E-06
	S.E	0,55	1,9 E-06	0,56	2 E-06	0,60	2,4 E-06



**Figura 6.** Valores de Kappa Global para as quatro técnicas de classificação estudadas nos três diferentes tipos de entrada de dados (originais, equalizadas, MLME).

**Tabela 2.** Kappa global ( $K_g$ ) e sua variância (Var) para as diferentes classificações e tipos variados de pré-processamento.

Algoritmo	Originais		Ajustadas		MLME	
	$K_g$	Var	$K_g$	Var	$K_g$	Var
Battacharya	0,69	4,5E-07	0,68	4,5E-07	0,66	4,7E-07
Isoseg	0,56	4,8E-07	<b>0,71</b>	4,3E-07	<b>0,71</b>	4,3E-07
K-médias	0,65	4,7E-07	0,67	4,7E-07	0,64	4,8E-07
MaxVer	<b>0,70</b>	4,3E-07	0,69	4,3E-07	0,68	4,4E-07

## CONCLUSÕES

Cada classificador demonstrou melhor desempenho na distinção de uma classe de uso e cobertura da terra específica. O classificadores MaxVer, K-médias e Battacharya foram mais adequados para a discriminação das classes floresta, floresta secundária e solo exposto respectivamente. Não houve diferença expressiva no desempenho global dos algoritmos em função do tipo de entrada de dados. O algoritmo Isoseg obteve a maior acurácia global quando os parâmetros: média e variância, foram semelhantes entre as bandas (ajuste e modelo de mistura).

Considerando-se as restrições de capacidade de armazenamento e processamento de dados e de pessoal qualificado, assim como a necessidade de correções para elaboração de um mapa, um sistema deve apresentar bom desempenho na classificação, mas também, em outros aspectos, como, por exemplo, a facilidade de uso, a rapidez de processamento e a economia de utilização de meios computacionais. Seu funcionamento exige, também, a participação de especialistas na região e em processamento de imagens. Por outro lado, o sistema deve oferecer uma variedade de ferramentas já que os problemas de classificação para o mapeamento do uso da terra transcendem a simples dicotomia como a distinção desflorestado/não desflorestado.

## AGRADECIMENTOS

Agradecemos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão das bolsas de estudos. Somos gratos à Dr<sup>a</sup>. Maria Isabel Sobral Escada pelo auxílio no reconhecimento dos padrões da área de estudo, a Dr<sup>a</sup> Leila Maria Garcia Fonseca pelas opiniões expressas sobre o processo metodológico e ao Dr. Diógenes Salas Alves por disponibilizar a imagem georreferenciada da área de estudo.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, D. S.; ESCADA, M. I. S.; PEREIRA, J. L. G.; ALBUQUERQUE LINHARES, C. 2003. Land use intensification and abandonment in Rondônia, Brazilian Amazonia. **International Journal of Remote Sensing**. v.24, n.4, p. 899-903.

ALVES, D. S.; PEREIRA, J. L. G.; SOUSA, C. L.; SOARES, J. V.; YAMAGUCHI, F. 1999. Characterizing landscape changes in central Rondonia using Landsat TM imagery. **International Journal of Remote Sensing**. v.20, n. 14, p. 2877-2882.

ALVES, D. S.; PEREIRA, J. L. G. ; SOUZA de, C. L.; SOARES, J. V.; MOREIRA, J. C.; ORTIZ, J. O.; SHIMABUKURO, Y. E.; YAMAGUCHI, F. 1998. Análise comparativa de técnicas de classificação de imagens do sensor Landsat/TM para caracterização de áreas desflorestadas. In: **Anais IX Simpósio Brasileiro de Sensoriamento Remoto – SBSR/INPE** p.1409-1419.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and practices**. Ed. Lewis Publishers, New York, 1999. 137p.

FREITAS, S. R.; CRUZ, C. B. M. 2005. Análise de componentes principais e modelo linear de mistura na discriminação de classes de vegetação na Mata Atlântica. In: **Anais do XII Simpósio Brasileiro de Sensoriamento Remoto - SBSR/INPE**, Goiânia. p. 1529-1536.

LANDIS, J. R., KOCH, C. H. 1977. The Measurement of Observer Agreement for Categorical Data. **Biometrics**. v.33, n.1, p. 159-174.

MORAN, E. F.; BRONDIZIO, E.; MAUSEL, P.; WU, Y. 1994. Integrating Amazonian Vegetation, Land-use, and Satellite Data. **BioScience**. v. 44, n. 5, p. 329-338.

RADAMBRASIL, Projeto. Levantamento de Recursos Naturais, Folha SC.20 – Porto Velho, Vol. 16. **DNPM/Projeto RADAMBRASIL**, Rio de Janeiro, 1978.

SHIMABUKURO, Y. E.; SMITH, J. A. 1991. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, p. 16-20.

SKOLE, D.; TUCKER, C. 1993. Tropical Deforestation and Habitat Fragmentation in the Amazon: Satellite Data from 1978 to 1988. **Science**. v.260, p.1905-1910.