

Dinâmica do uso e cobertura da terra no sudeste de Roraima utilizando técnicas de detecção de mudanças

Maristela Ramalho XAUD^{1, 2, *}, José Carlos Neves EPIPHANIO¹

¹ Instituto Nacional de Pesquisas Espaciais – INPE. Av. dos Astronautas, 1758, CEP: 12.227-010. São José dos Campos, São Paulo, Brasil.
mramalho@dsr.inpe.br, epiphanio@dsr.inpe.br

² Empresa Brasileira de Pesquisa Agropecuária – Embrapa Roraima. BR-174, km 8, Distrito Industrial. Boa Vista, Roraima, Brasil.

* Autor Correspondente: maristela.xaud@embrapa.br

RESUMO

A ocupação e consolidação do território na Amazônia apresentam diferentes características relacionadas à dinâmica das conversões de uso e cobertura da terra, que podem ser analisadas utilizando imagens orbitais de sensoriamento remoto. O objetivo do presente trabalho foi avaliar os produtos de detecção de mudanças gerados por análise de vetor de mudança (AVM) e subtração de imagens, a partir de imagens-fração derivadas das imagens ópticas TM/Landsat, para o estudo das conversões de uso e cobertura da terra presentes em área de colonização agrícola na região sudeste de Roraima. Analisaram-se as imagens de mudança provenientes da aplicação do AVM (magnitude, alfa e beta) e da subtração das imagens-fração (solo, sombra e vegetação) quanto à sua capacidade de identificar e discriminar as conversões existentes, de acordo com levantamento de campo. Foram testados dois algoritmos de classificação de imagens do tipo supervisionado, *Bhattacharyya* e *Support Vector Machine*. Foram feitos agrupamentos para otimizar a identificação das conversões nas classificações testadas. Houve melhor desempenho do classificador por regiões *Bhattacharyya* na discriminação das conversões. A utilização das imagens-diferença das frações como informação de entrada para o classificador apresentou qualidade de classificação muito boa ou excelente, sendo superior às classificações utilizando os produtos AVM, isoladamente ou em conjunto com as imagens-diferença.

PALAVRAS-CHAVE: uso da terra, detecção de mudança, imagens-fração, sensoriamento remoto, Amazônia.

Land use and land cover dynamics in the southeastern Roraima using change detection techniques

ABSTRACT

Territory occupation and consolidation in the Amazon region have some specific characteristics related to the dynamics of land use and land cover conversions, which can be analyzed using orbital remote sensing images. The aim of this study was to evaluate change detection products generated by change vector analysis (AVM) and image subtraction techniques derived from linear spectral mixing modeling (MLME), applied to Thematic Mapper/Landsat optical images, to study land use and land cover conversions occurring in agricultural settlement areas in the southeastern region of Roraima, Brazil. We analyzed change images derived from application of AVM (magnitude, alpha and beta) and subtraction of fraction images (soil, vegetation and shade), for their ability to identify and discriminate the existing conversions. An extensive field work was used as a guide to define the classes. Exploratory analyses of class behaviors were made and two supervised algorithms for image classification - *Bhattacharyya* and *Support Vector Machine* - were tested. By grouping (clumping classes), we sought to optimize conversion identification in the classification products. The results indicated better *Bhattacharyya* region classifier performance of conversion discrimination. The use of MLME fractions difference images as input into the classifier resulted a very good or excellent classification quality, which was better in comparison with products using AVM images, either in isolation or in conjunction with MLME difference images.

KEYWORDS: Land use, change detection, fraction images, remote sensing, Amazon.

INTRODUÇÃO

As mudanças de uso e cobertura da terra vêm alterando os ciclos biogeoquímicos, o balanço de radiação e o sistema climático terrestre, tendo relação direta com as emissões de gases do efeito estufa. Como parte integrante da análise de dados de sensoriamento remoto, o processamento digital de imagens apresenta diversas ferramentas que buscam otimizar a extração da informação desejada. Entre os processamentos digitais para tratamento das imagens ópticas, relacionados à identificação e à quantificação de mudanças na Amazônia, destaca-se o modelo linear de mistura espectral (MLME) e as técnicas de detecção de mudanças (Adams *et al.* 1995; Shimabukuro *et al.* 1998; Lu *et al.* 2003).

O MLME além de permitir a extração repetitiva e quantitativa de informação ao nível do *subpixel* (Smith *et al.* 1990; Roberts *et al.* 1998), origina imagens-fração, com significado físico dos alvos e da cobertura terrestre. Atualmente, várias aplicações no monitoramento do desmatamento, de áreas degradadas e na classificação do uso e cobertura da terra na Amazônia brasileira têm incluído o MLME na metodologia de extração de informações dos alvos (INPE 2008).

As técnicas de detecção de mudanças também apresentam elevado potencial exploratório, entre elas a análise por vetor de mudança (AVM), técnica multivariada que trabalha com a total dimensionalidade (espectral e temporal) dos dados das imagens (Malila 1980; Lambin e Strahler 1994; Johnson e Kasischke 1998). No ambiente amazônico, a capacidade da AVM foi testada em estratificar conversões e modificações relacionadas ao uso e cobertura da terra e na detecção da exploração madeireira (Silva *et al.* 2003; Graça 2004; Lorena *et al.* 2004). A subtração de imagens é outra técnica de detecção de mudanças que apresenta bons resultados na análise multitemporal de mudanças da cobertura vegetal, sendo testada também na região amazônica (Rogan *et al.* 2002; Haertel *et al.* 2004; Lu *et al.* 2005).

O objetivo do presente trabalho foi avaliar os produtos de detecção de mudanças gerados pelas técnicas AVM e subtração de imagens, utilizando imagens-fração derivadas do MLME, a partir de imagens ópticas TM/Landsat, para o estudo das conversões de uso e cobertura da terra que ocorrem na região sudeste de Roraima.

MATERIAL E MÉTODOS

Área de estudo

A área de estudo está situada na porção sudeste do Estado de Roraima, correspondendo a quatro glebas de colonização (Colônias de São João da Baliza, São Luizão, Caroebe e Entre Rios), localizadas nos municípios de São João da Baliza e Caroebe, com extensão total de 2653 km². (Figura 1).

A região apresenta cinco tipos de solo: Argissolo Vermelho-Amarelo distrófico, Latossolo Amarelo distrófico, Argissolo Amarelo distrófico plúntico, Latossolo Vermelho-Amarelo distrófico, Neossolo litólico distrófico com Afloramentos Rochosos (EMBRAPA 1999; IBGE 2005). A vegetação predominante nesta área é representada pela Floresta Ombrófila Densa Submontana. O relevo da área varia de plano a ondulado, predominando as áreas suaves onduladas (IBGE 2005). De acordo com a classificação de Köppen, o clima da região é do tipo Am e caracteriza-se por uma estação seca definida, correspondendo ao período de dezembro a março. O índice pluviométrico médio anual varia de 1700 a 2000 mm, ocorrendo o máximo (40% das chuvas) no período de maio a julho (Barbosa 1997).

Atualmente, a região destaca-se no Estado com a cultura da banana, produzida em pequenas propriedades, e com a pecuária, que se desenvolve em pequenas e médias propriedades (Mourão 2008).

Processamento de imagens

No presente estudo, foram utilizadas imagens digitais do sensor TM/Landsat-5, cena 231/59, dos anos de 2004 (14/10/2004) e 2010 (28/08/2010) com resolução de 30 metros e seis bandas (1, 2, 3, 4, 5 e 7), do acervo de cenas do *United States Geological Survey* (USGS), disponível de modo ortorretificado na plataforma GLOVIS (www.glovis.usgs.gov). A base cartográfica foi composta por dados oficiais da malha municipal do IBGE e dados complementares do Zoneamento Ecológico-Econômico do Estado de Roraima (CPRM 2003). As imagens correspondem ao final da estação chuvosa na região (agosto a outubro), quando boa parte das culturas anuais está sendo ou já foi colhida. As culturas semi-perenes apresentam alto vigor vegetativo, como é o caso da banana na região. Dentro do calendário de práticas agrícolas, este também é o início do período de derrubada, que antecede à queimada, na abertura de novas áreas.

No processamento das imagens, foram utilizados os softwares ENVI/IDL e SPRING (Sistemas de Processamento de Informações Georreferenciadas). Inicialmente foram realizadas as etapas de calibração, correção atmosférica e normalização radiométrica, com o intuito de minimizar características que não pertencem aos alvos das cenas imageadas (ruídos do sensor, atmosfera, nuvens, etc.) e tornar as imagens multitemporais radiometricamente comparáveis entre si (Ponzoni *et al.* 2007).

Na calibração das imagens, foi realizada a correção radiométrica. Nesta operação, os valores dos *pixels* foram convertidos para reflectância exoatmosférica, levando em consideração os parâmetros de calibração para a data de aquisição, como o ângulo zenital solar e a irradiância solar normalizada. Para a correção atmosférica, foi utilizado

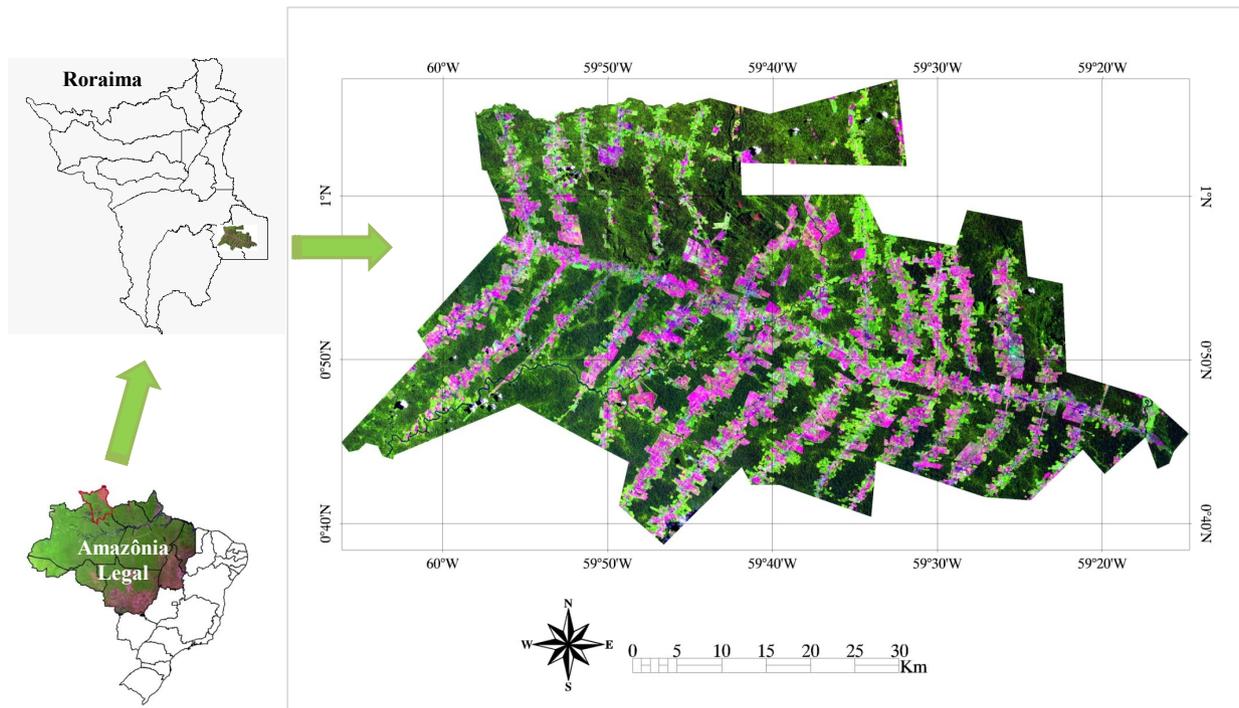


Figura 1 - Localização da área de estudo no sudeste do Estado de Roraima. Composição colorida (versão digital): banda 3-azul; banda 4-verde; banda 5-vermelho, da imagem TM/Landsat, órbita-ponto 231/59, de 28/08/2010. (figura colorida na versão eletrônica).

o método da transferência radiativa, que leva em conta os processos de absorção e espalhamento atmosféricos (Matthew *et al.* 2003). Utilizou-se o algoritmo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*), implementado no ENVI, para a imagem de 2004, escolhida para ser a referência da série temporal, em função da menor cobertura de nuvens. A imagem de 2010 foi normalizada radiometricamente em relação à referência, segundo um método proposto por Canty *et al.* (2004), o qual utiliza uma transformação linear para identificar *pixels* de não-mudança, definindo uma função de normalização entre a referência e a imagem. Utilizou-se o algoritmo iMAD, desenvolvido e aperfeiçoado para utilização com o ENVI (Canty e Nielsen 2008; Nielsen 2007).

Modelo linear de mistura espectral

As imagens corrigidas e calibradas foram decompostas em seus componentes puros usando um modelo linear de mistura espectral (MLME). Foram considerados três componentes na aplicação do modelo: solo, sombra e vegetação (Shimabukuro e Smith 1991). Os *pixels* puros candidatos foram obtidos na imagem referência (2004) utilizando o algoritmo de Índice de Pureza de Pixel – PPI (Boardman *et al.* 1995), implementado no ENVI. Esses *pixels* foram inspecionados quanto à curva espectral e comparados aos espectros de amostras de solo exposto, água e vegetação verde, identificados na imagem,

gerando o MLME a ser aplicado às imagens de 2004 e 2010. A geração das imagens-fração foi realizada utilizando as seis bandas ópticas das imagens da série, formando um sistema de equações lineares, resolvido pelo método dos Mínimos Quadrados, com restrição (0-1). O valor do erro médio quadrático (RMS) e a sua distribuição foram utilizados para verificar o ajuste do modelo.

Análise do vetor de mudança

A análise do vetor de mudança (AVM) foi aplicada às imagens-fração com o intuito de caracterizar as mudanças ocorridas entre as imagens. Um vetor de mudança é definido pela diferença na posição espectral de um mesmo *pixel* em tempos distintos de sua trajetória, representado em um espaço n-dimensional (Johnson e Kasischke 1998), indicando a intensidade e a natureza (ou direção) de mudança na superfície da terra e sendo descrito em termos de: (1) magnitude ($\mu = ((x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2)^{0,5}$); (2) ângulo alfa ($\alpha = \arctg((y_2 - y_1)/(x_2 - x_1))$); e (3) ângulo beta ($\beta = \arcsen((z_2 - z_1)/\mu)$), onde $(x_2 - x_1)$, $(y_2 - y_1)$ e $(z_2 - z_1)$ representam a diferença entre os valores dos *pixels* entre t_1 e t_2 para cada imagem-fração, sendo x correspondente ao componente solo, y ao componente vegetação e z ao componente sombra, conforme observado na Figura 2-A (Silva *et al.* 2003; Graça 2004; Castillo 2011). A formulação do ângulo alfa retorna valores no intervalo de $-\pi/2$ a $+\pi/2$ radianos (correspondente ao 1º e 4º quadrante da

esfera), o que limita a análise da imagem alfa, que tem variação angular correspondente a toda esfera ($-\pi$ a $+\pi$ radianos). Para essa correção, são realizados ajustes atendendo às condições apresentadas de forma esquemática na Figura 2-B.

Subtração de imagens

A subtração das imagens-fração também foi aplicada como técnica de detecção de mudança visando avaliar sua aplicabilidade na análise das conversões. A álgebra de imagens envolve operações aritméticas aplicadas aos pixels em cada imagem co-registrada, cujo resultado é a imagem diferença (no caso da subtração). Essa técnica é a mais amplamente utilizada entre os algoritmos de detecção de mudanças, podendo ser aplicada tanto nas bandas originais como nas bandas transformadas. Ela envolve a subtração da imagem de uma data pela imagem de uma segunda data, que deve estar precisamente registrada com a primeira, cujo resultado será uma imagem onde os valores positivos e negativos representam as áreas de mudança e os valores mais próximos de zero representam áreas de não-mudança (Coppin *et al.* 2004).

Levantamento de dados em campo

O trabalho de campo contou com duas etapas: a primeira, exploratória (janeiro de 2010), teve o objetivo de fazer uma caracterização das classes de uso e cobertura da terra; e a segunda, mais detalhada (novembro de 2010), procurou juntar à identificação de classes novas informações provenientes de questionários aplicados junto aos atores locais, visando ao resgate histórico das características das mudanças ocorridas na região. Assim, foram identificadas as principais classes e conversões na área de estudo, bem como as áreas de não-

mudança, onde não houve alteração de classe entre uma data e outra (Tabela 1).

As classes de uso e cobertura da terra e as conversões identificadas foram caracterizadas quanto à sua dinâmica no processo de ocupação e uso da terra na região, de acordo com as entrevistas realizadas em campo e informações de trabalhos anteriores na região (Barros 1995; Mourão 2008).

Tendo em vista a disponibilidade de acesso e a importância do domínio da cultura da banana na classe agricultura nas imagens estudadas, foram incorporados adicionalmente dados georreferenciados das áreas de cultivo de banana, levantados junto a técnicos da Agência de Defesa Vegetal e Animal de Roraima (ADERR), com informações cadastrais das áreas plantadas (tamanho das áreas, idade dos bananais etc.).

Extração e análise da informação

Como forma de avaliar o potencial dos produtos gerados pelas técnicas de detecção de mudanças utilizadas, para cada imagem de mudança (magnitude, alfa, beta e as imagens-diferença entre imagens-fração), foram extraídas as médias das amostras de cada uma das conversões identificadas, tendo como base as entrevistas realizadas, os pontos amostrais verificados em campo e as regiões homogêneas onde estão inseridas.

Para determinação das regiões homogêneas e seleção das amostras, foi utilizada uma segmentação do tipo crescimento de regiões, com limiares 15 e 30 (similaridade e área), realizada sobre as seis bandas originais da imagem de 2010. Essa técnica de agrupamento de dados permite a agregação de regiões uniformes adjacentes de acordo com os limiares escolhidos,

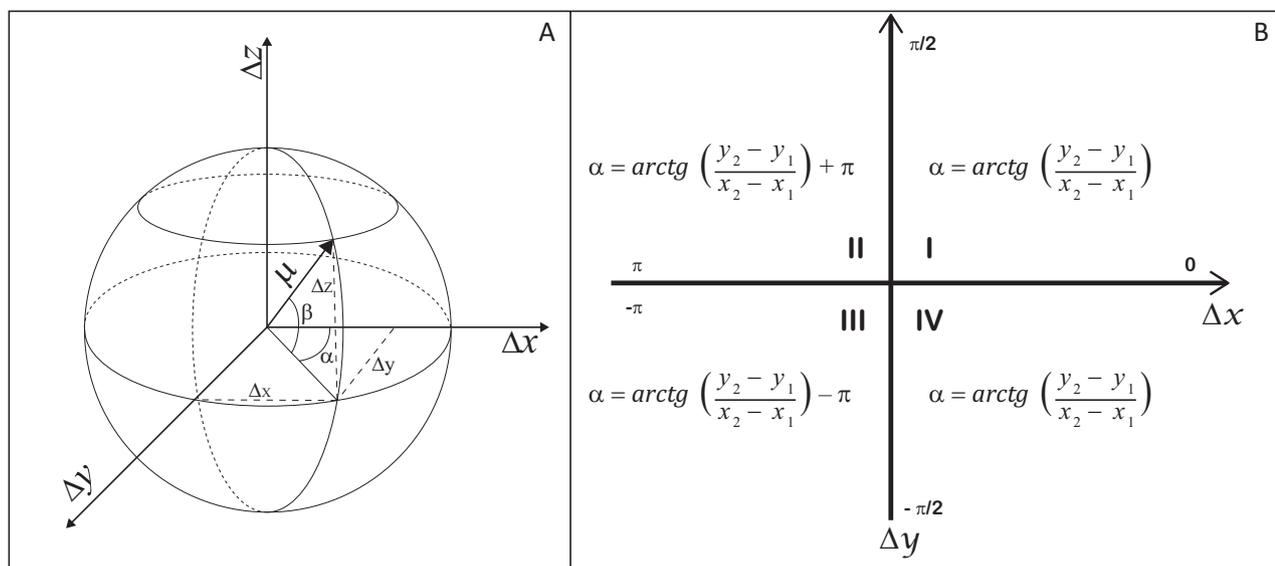


Figura 2 - Representação do vetor de mudança: (A) Componentes (μ : magnitude, α : ângulo alfa e β : ângulo beta) em um sistema de coordenadas esféricas; (B) Representação esquemática do cálculo do ângulo alfa de acordo com o quadrante, sendo $(x_2 - x_1)$ e $(y_2 - y_1)$ a diferença entre os valores dos pixels em t_1 e t_2 para cada imagem-fração, sendo x correspondente ao componente solo e y ao componente vegetação. Adaptado de Graça (2004).

Tabela 1 - Classes de uso e cobertura da terra, conversões e áreas de não-mudança encontradas na área de estudo.

CLASSES DE USO E COBERTURA DA TERRA	CONVERSÕES IDENTIFICADAS	ÁREAS DE NÃO-MUDANÇA
F: Floresta (primária)	FC: floresta-capoeira	FF: floresta-floresta
C: Capoeira (sucessão secundária)	FP: floresta-pasto	CC: capoeira-capoeira
A: Agricultura	FA: floresta-agricultura	AA: agricultura-agricultura
P: Pasto	CP: capoeira-pasto	PP: pasto-pasto
	CA: capoeira-agricultura	
	PC: pasto-capoeira	
	PA: pasto-agricultura	
	AP: agricultura-pasto	
	AC: agricultura-capoeira	

similaridade (baseada na distância Euclidiana entre os valores médios de cada região) e área (tamanho mínimo, em *pixels*, para a região ser agregada).

Os dados levantados em campo (pontos amostrais, entrevistas, dados cadastrais da cultura da banana) e a interpretação visual da imagem de 2004 foram utilizados para identificar o uso e cobertura anterior. As médias das amostras foram analisadas estatisticamente no *R-Project* (R Development Core Team 2011), de forma exploratória, visando auxiliar as classificações realizadas e separar as principais conversões ocorridas na região. O comportamento de cada conversão foi analisado univariadamente para cada produto (AVM e subtração das imagens-fração).

Com enfoque de classificar as mudanças (conversões) e não classes de uso e cobertura da terra (abordagem mais convencional), foram utilizados dois diferentes algoritmos de classificação de imagens, do tipo supervisionado, visando avaliar o que melhor discriminasse as classes de interesse. O primeiro denominado *Bhattacharyya* é baseado na classificação de regiões que permite associar cada região com uma das classes, utilizando-se o critério de distância mínima. Cada região e cada classe são descritas estatisticamente através dos vetores de médias e das matrizes de covariância calculados no espaço de atributos, onde é possível calcular a distância entre duas massas de dados (a região e a classe) através da distância de *Bhattacharyya* (Mather 1999; Richards e Jia 2006). O segundo, *Support Vector Machine* (SVM), algoritmo baseado em treinamento de máquina, realiza a classificação *pixel a pixel*. O SVM constrói um hiperplano como superfície de decisão, maximizando a margem de separação entre as classes (Sousa *et al* 2010). A diferença entre classificadores “*pixel a pixel*” e por regiões está na unidade a ser classificada, no caso da primeira são *pixels* individuais e na segunda são regiões geradas por uma prévia segmentação da imagem (Richards e Jia 2006). A segmentação e seus limiares (similaridade e área) são importantes componentes no delineamento e reconhecimento espectral da região e da posterior classificação (Schoenmakers

et al. 1991). A segmentação, no caso do presente trabalho, foi do tipo crescimento por regiões e delimitou as amostras de treinamento de forma a permitir a comparabilidade entre os diferentes classificadores.

As classes de não-mudança (FF, CC, AA e PP) foram agrupadas em uma única classe denominada de áreas de não-mudança (Tabela 1). A validação do desempenho das classificações foi realizada através do grau de exatidão total e da exatidão por classes, decorrendo no índice de concordância *Kappa* (Landis e Koch 1977). A partir dos valores de *Kappa* encontrados para cada classificação, foi realizado um teste estatístico Z para verificar, dois a dois, se havia diferença significativa entre os resultados.

RESULTADOS

Caracterização e amostragem das conversões

No resgate histórico do uso e cobertura da terra na região através da análise dos questionários e das imagens, foram identificadas (Tabela 1) e caracterizadas as principais conversões entre classes predominantes na área de estudo (Tabela 2). A conversão PA (pasto-agricultura) foi identificada na região, porém com incipiente expressão no período estudado. Em função disso, ela foi desconsiderada nas análises subsequentes.

Análise exploratória das conversões

O comportamento de cada conversão nos produtos gerados pode também ser observado através da análise exploratória dos gráficos do tipo *boxplot*, com as representações dos parâmetros descritivos do primeiro e terceiro quartil, além da mediana (Figura 3). Cada imagem de mudança, de maneira individualizada, mostrou-se potencial em separar classes de conversão. Os pares de conversões FC (floresta-capoeira) e FA (floresta-agricultura); CP (capoeira-pasto) e AP (agricultura-pasto); e CA (capoeira-agricultura) e AC (agricultura-capoeira) mostram-se de mais difícil separabilidade entre si em todas as imagens analisadas.

Processamento digital de imagens

Os resultados da etapa de pré-processamento visando à correção atmosférica e ao devido ajuste radiométrico entre as imagens (2004 e 2010) foram considerados satisfatórios. Os valores *p-value* maiores que 0,1, obtidos após aplicação do algoritmo iMAD, indicaram que as médias e as variâncias dos valores dos *pixels* invariantes da imagem referência (2004) e da imagem normalizada (2010) não apresentam diferenças significativas (Canty *et al.* 2004). Os componentes puros selecionados para a geração das imagens fração sombra, solo e vegetação, derivadas do MLME, foram obtidos na imagem ajustada de 2004 e utilizados também na obtenção das imagens fração da imagem 2010. Os erros médios quadráticos do modelo (RMS – *Root Mean Squared "error"*) foram considerados adequados (1,6 para a imagem de 2004 e 1,9 para a imagem de 2010), correspondendo a menos de dois níveis de cinza das imagens, o que equivale ao ruído do sensor (Smith *et al.* 1990).

Análise do vetor de mudança

As imagens resultantes da AVM aplicada às imagens-fração do MLME forneceram informações sobre a intensidade e a direção das mudanças de uso e cobertura da terra no período analisado. Os valores das conversões na imagem magnitude

variaram de 0,08 a 1,09, indicando a intensidade das mudanças ocorridas. Os valores próximos a zero indicaram mudanças de baixa intensidade entre os alvos da superfície terrestre. No outro extremo, valores próximos de 1,0 representaram mudanças intensas ocorridas na cobertura da terra entre as datas analisadas. Os resultados assemelham-se a Graça (2004), que encontrou valores de magnitude próximos a 1,0 em pátios de estocagem de madeira, indicando forte mudança, e valores próximos a zero nas áreas de floresta primária (não mudança).

Os maiores valores de magnitude estiveram presentes nas conversões FP, CP, PC e AP. Esse comportamento se justifica pela característica das mudanças que derivam na classe pasto e também na conversão pasto-capoeira, no âmbito das imagens-fração. Há diferença mais acentuada principalmente nas frações solo (para FP, CP e AP) e na fração vegetação (para PC). Essa diferença é da ordem de 0,3, em média, nas conversões CP e AP (na subtração das imagens-solo) e PC (na subtração das imagens-vegetação) e 0,4 na conversão FP (na subtração das imagens-solo). No caso da conversão floresta-pasto, há também diferença na fração sombra que, apesar de menor (média de 0,15), eleva ainda mais o valor da magnitude dessa conversão. Essa baixa diferença entre as frações sombra pode ter relação com o estado da classe pasto ao final da estação chuvosa (muita umidade e presença de

Tabela 2 - Caracterização das conversões identificadas e amostragem para cada conversão.

CONVERSÕES IDENTIFICADAS	CARACTERÍSTICAS	AMOSTRAGEM (amostras/pixels)
FC: floresta-capoeira	Conversão com perda média de biomassa, presente tanto no sistema produtivo agrícola como na atividade pecuária.	38/3551
FP: floresta-pasto	Conversão com alta perda de biomassa presente na atividade pecuária, vinculada a aberturas médias a grandes em áreas florestais (>10 ha anuais).	83/6657
FA: floresta-agricultura	Conversão com perda média de biomassa presente na atividade agrícola, vinculada a pequenas aberturas (3-6 ha anuais).	98/8808
CP: capoeira-pasto	Conversão com baixa perda de biomassa presente na atividade pecuária, podendo estar vinculada a agricultores familiares na diversificação da propriedade (pequenas áreas) ou a pecuaristas no manejo das pastagens (áreas médias a grandes).	35/3715
CA: capoeira-agricultura	Conversão com baixa perda de biomassa presente na atividade agrícola dos agricultores familiares na intensificação das atividades na propriedade, relacionada ao fim do pousio agrícola.	28/2133
PC: pasto-capoeira	Conversão com baixo ganho de biomassa presente na atividade pecuária, relacionada à diminuição da atividade, problemas de manejo de pastagens ou abandono da propriedade.	33/2417
PA: pasto-agricultura	Conversão com baixo a médio ganho de biomassa presente na atividade agropecuária, com necessidade de alto aporte de insumos e tecnologia.	3/223
AP: agricultura-pasto	Conversão com baixa perda de biomassa presente na atividade agropecuária, com pouca necessidade de insumos e mão-de-obra, vinculada a agricultores familiares no manejo da propriedade.	46/4700
AC: agricultura-capoeira	Conversão com baixo ganho de biomassa presente na atividade agrícola, relacionada ao final do ciclo da cultura e início do período de pousio.	31/2635

ha: hectare

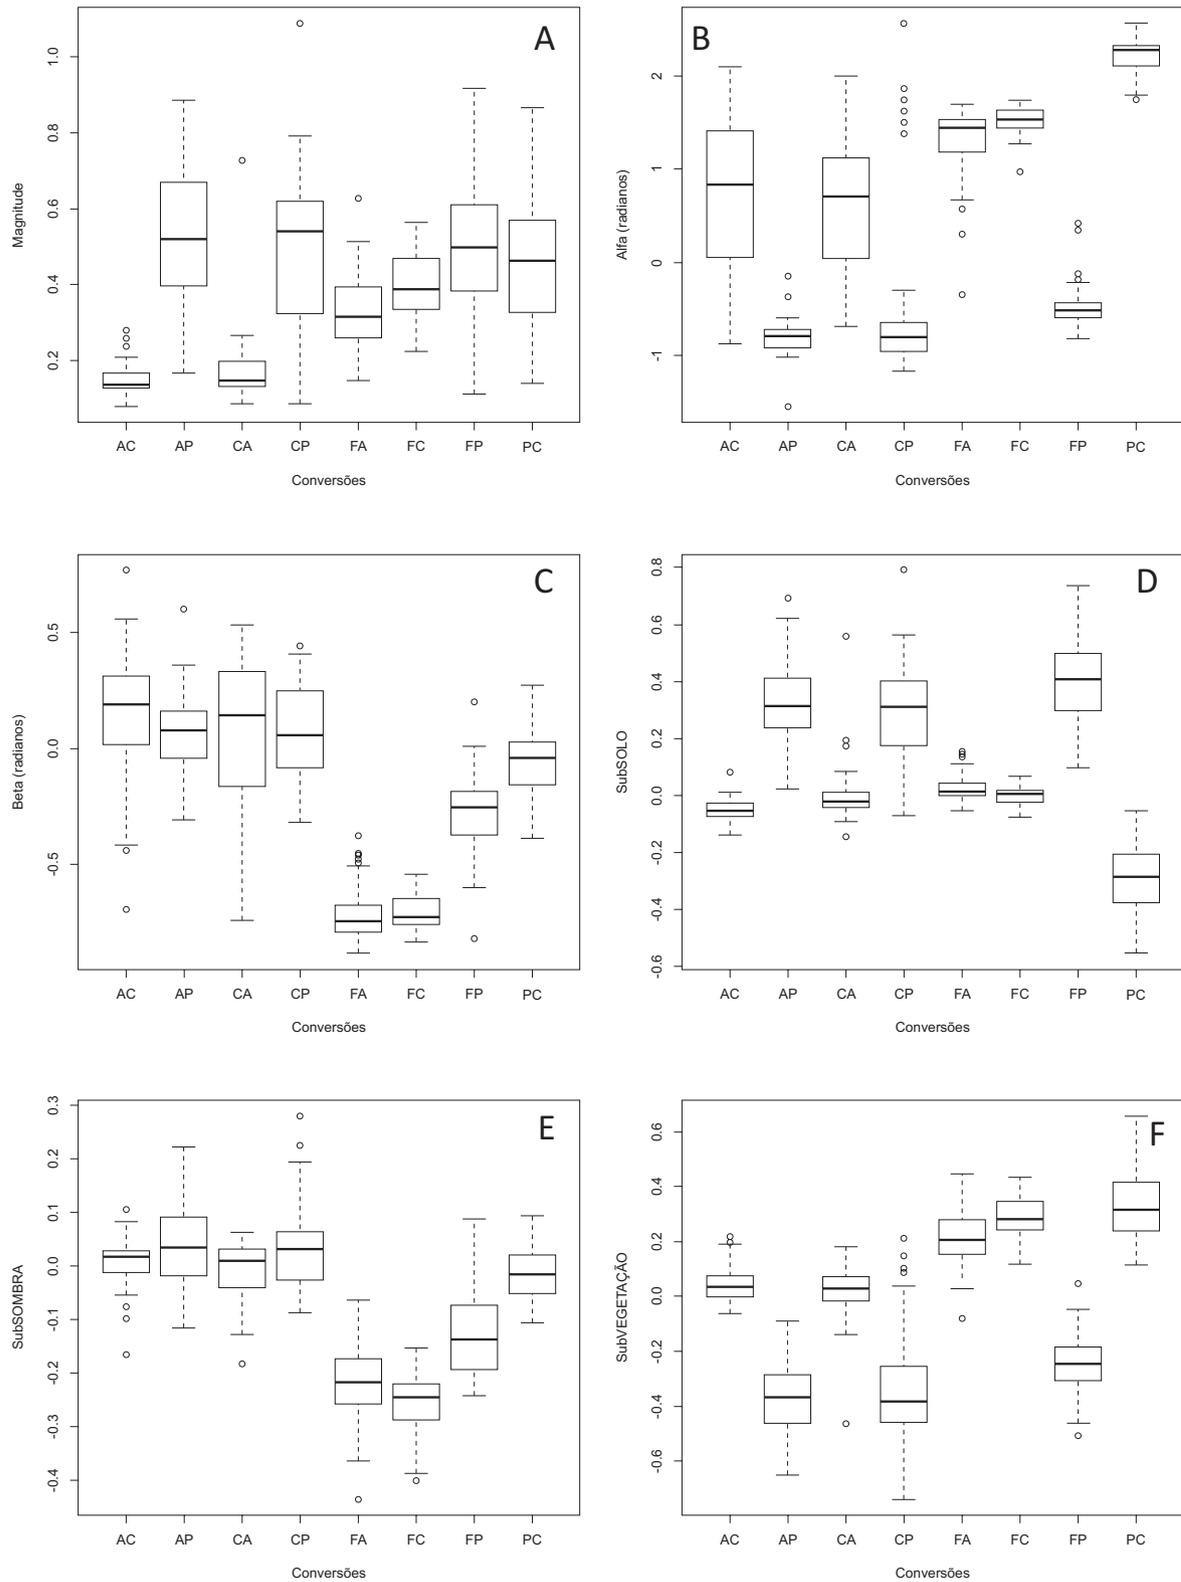


Figura 3 - Boxplots dos valores médios das amostras nas imagens de mudança: (a) magnitude, (b) alfa, (c) beta, (d) subtração das imagens-fração solo, (e) subtração das imagens-fração sombra e (f) subtração das imagens-fração vegetação. Conversões (eixo horizontal) = AC: agricultura-capoeira; AP: agricultura-pasto; CA: capoeira-agricultura; CP: capoeira-pasto; FA: floresta-agricultura; FC: floresta-capoeira; FP: floresta-pasto; PC: pasto-capoeira.

indivíduos arbustivos típicos de estádios sucessionais), assim como com a possibilidade da classe pasto incorporar no espaço de atributos, áreas recém-colhidas das culturas anuais de similar característica espectral. Os menores valores tiveram relação com as conversões CA e AC, nas quais as imagens-fração pouco variaram (diferença próxima a zero em todas as frações), em função das características da classe agricultura (dominada pela bananicultura) e da classe capoeira (vegetação em regeneração) na região nas datas estudadas. Conforme observado em trabalho de campo, essas conversões são sutis em relação às imagens-fração, uma vez que as áreas de cultura da banana apresentam características semelhantes às áreas de sucessão secundária na região, com estágio inicial a partir do abandono do bananal.

As imagens angulares, alfa e beta, forneceram informações sobre a direção das mudanças ocorridas. A imagem alfa variou no intervalo de $-\pi$ a π radianos, apresentando valores negativos nas conversões que derivaram na classe pasto (FP, CP e AP), indicando perda de biomassa. Os valores positivos de alfa variaram entre conversões com baixa variação de biomassa, ou seja, baixa perda de biomassa (FC e FA) ou com baixo ganho de biomassa (PC), segundo as características das conversões observadas em campo, uma vez que na classe agricultura predomina a bananicultura, com elevado valor de biomassa aérea em relação a outras culturas. A classe capoeira (sucessão secundária), derivada de antigos bananais hoje abandonados, também representa baixa perda de biomassa em relação às áreas florestais originais, quando comparadas às outras conversões presentes na área. A indicação de perda ou ganho de biomassa está associada à formulação do ângulo alfa e ao sinal correspondente ao quadrante onde a conversão está posicionada. Quando a diferença entre os valores dos pixels na imagem-fração de vegetação for menor que a diferença na imagem-fração solo indicará maiores valores de alfa. A imagem beta, com valores variando entre $-\pi/2$ e $\pi/2$ radianos, indicou diminuição ou aumento do componente sombra nas conversões analisadas. De acordo com a formulação do ângulo beta, a diminuição de sombra está associada a valores negativos de beta, ou seja, quando a diferença entre os valores de um mesmo *pixel* na imagem final e inicial da fração sombra (Δz) foi menor que zero, já que o valor de magnitude é sempre positivo. Analogamente, o aumento de sombra está associado a valores de Δz maiores do que zero. As conversões FC, FP e FA apresentaram valores negativos de beta, ao passo que a conversão AC foi a que apresentou mais valores positivos de beta.

Subtração das imagens-fração

As imagens-diferença resultantes da subtração entre as duas datas forneceram informação sobre a variação de cada conversão nos componentes selecionados para o modelo, no caso solo, sombra e vegetação. Valores positivos indicaram

aumento da influência do componente da primeira data em relação à segunda data. De forma análoga, valores negativos indicaram diminuição do componente e os valores próximos a zero indicaram pouca variação do componente no período estudado.

Na subtração das imagens-fração de solo, as conversões FP, CP e AP apresentaram valores positivos, enquanto que a conversão PC apresentou valor negativo. As demais permaneceram próximas a zero. Esse resultado evidencia a influência da classe pasto nesse componente. Na subtração das imagens-fração de sombra, as conversões FC, FP e FA apresentaram valores negativos, enquanto que as demais ficaram próximas a zero. A fração sombra, muito presente na classe floresta, e a sucessiva conversão para outra classe foi determinante para esse resultado. Valores positivos foram observados nas conversões CP e AP, que podem ser explicados por alguma presença de umidade ou restos culturais ou vegetativos na classe pasto, em função da época das imagens estudadas. Na subtração das imagens-fração de vegetação, as conversões FC, FA e PC apresentaram valores positivos, ao passo que FP, CP e AP apresentaram valores negativos. Esse comportamento indica que o componente vegetação tem forte presença principalmente nas classes capoeira e agricultura, determinando diminuição nas conversões em direção à classe pasto e aumento nas conversões direcionadas à regeneração vegetal e à agricultura.

Classificação supervisionada das conversões

Foram analisados os resultados das classificações *Bhattacharyya* e SVM tendo como base de entrada três combinações de produtos: (1) as três imagens do AVM (magnitude, alfa e beta); (2) as três imagens oriundas das subtrações de bandas do MLME (subtrações das imagens-solo, das imagens-sombra e das imagens-vegetação); e (3) os seis produtos (AVM e subtrações do MLME).

Foram realizados testes utilizando as conversões identificadas e a classe reunida de não-mudança (nove classes), além de agrupamentos de conversões, considerando as características das conversões da região de estudo. Dessa forma, foram realizados dois tipos de agrupamentos, o primeiro em função da perda e do ganho de biomassa aérea (agrupamento 1) e o segundo em função do tipo de classe final de uso da terra (agrupamento 2). O agrupamento 1 reuniu as conversões em quatro classes: conversões de alta perda de biomassa - TAPB (FP), conversões de média perda de biomassa - TMPB (FC e FA), conversões de baixa perda de biomassa - TBPB (CP, CA e AP) e conversões de baixo ganho de biomassa - TBGB (PC e AC). O agrupamento 2 reuniu as conversões também em quatro classes: conversões relacionadas a desmatamento - Grupo A (FC e FA); conversões influenciadas pela atividade pecuária - Grupo B (FP, CP e AP); conversões relativas às atividades de pousio agrícola - Grupo C (CA e AC); e

Tabela 3 - Valores dos índices *Kappa* e exatidão global da classificação *Bhattacharyya*, tendo como entrada: as imagens da análise de vetor de mudança (AVM) – magnitude, alfa e beta; as subtrações entre imagens-fração (solo, sombra e vegetação); todas (AVM e subtrações).

	AVM		Subtração das imagens-fração		AVM + Subtração	
	Kappa	Exatidão global (%)	Kappa	Exatidão global (%)	Kappa	Exatidão global (%)
Todas as conversões	0,5972 ^a	65,76	0,6674 ^{a*}	71,65	0,6137 ^a	67,19
Agrupamento 1	0,6529 ^a	72,69	0,7804 ^{b*}	82,76	0,732 ^b	79,05
Agrupamento 2	0,702 ^{ac}	77,69	0,8007 ^{b*}	85,06	0,7562 ^{bc}	81,82

^{a,b,c} : Valores com mesmo índice não diferem segundo o teste Z, a 5% de significância.

* Melhor desempenho classificatório

conversão relativa à diminuição da atividade pecuária – Grupo D (PC).

As amostras foram divididas em amostras de treinamento (50%) e amostras de teste (50%), de forma sistemática, sendo extraídas a partir do resultado da segmentação, tanto na forma de objetos para a classificação por região, como na forma de um conjunto de pixels representativos de cada classe (classificação pixel a pixel). O total de amostras e número de pixels encontram-se na Tabela 2.

Os classificadores mostraram desempenhos diferentes, com superioridade nos valores *Kappa* para o classificador por regiões *Bhattacharyya*, segundo o teste estatístico Z (Tabelas 3 e 4). Esse resultado pode estar relacionado à característica do classificador por regiões, na qual cada região é descrita estatisticamente, assim como cada classe, de forma a definir se a região pertence àquela classe, dependendo de uma distância mínima estabelecida. Por outro lado, na classificação SVM as amostras compõem um aglomerado de *pixels* independentes no espaço de atributos, sem a informação da região. Essa informação de contexto ou vizinhança parece ser relevante na discriminação das conversões estudadas, principalmente aquelas com elevada confusão com a classe não-mudança (conversões CA e AC).

Apenas nas classificações *Bhattacharyya* com as imagens AVM os agrupamentos não proporcionaram melhoria

significativa no índice *Kappa* (Tabela 3). Em todas as outras classificações, houve diferença significativa em função do agrupamento das conversões (Tabelas 3 e 4).

Não houve diferença significativa entre os agrupamentos 1 e 2 nas classificações com o algoritmo *Bhattacharyya* (Tabela 3). Já nas classificações SVM, os agrupamentos 1 e 2 apresentaram diferença significativa (Tabela 4). Isso pode ser explicado pela fraca capacidade do algoritmo SVM em separar as classes CA e AC da classe da não-mudança, afetando consequentemente a classe “Grupo C” (agrupamento 2), o que não ocorreu na classificação por regiões.

A diferença entre os dados de entrada nos classificadores só foi significativa nas classificações SVM considerando todas as conversões, diferenciando positivamente a classificação que utilizava unicamente as imagens-diferença entre as bandas do MLME (Tabela 4). Nas classificações *Bhattacharyya*, quando considerado o agrupamento 1, houve diferença significativa entre a que utilizava unicamente as bandas do AVM e as demais (Tabela 3).

Foram selecionadas as classificações com melhor desempenho em relação aos índices *Kappa* e exatidão global (Tabela 3), para a análise das matrizes de confusão entre classes (Tabela 5), visando à melhor discriminação das conversões, de acordo com a metodologia estabelecida.

Tabela 4 - Valores dos índices *Kappa* e exatidão global da classificação SVM¹ (*Support Vector Machine*), tendo como entrada: as imagens da análise de vetor de mudança (AVM) – magnitude, alfa e beta; as subtrações entre imagens-fração (solo, sombra e vegetação); todas (AVM e subtrações).

	AVM		Subtração das imagens-fração		AVM + Subtração	
	Kappa	Exatidão global (%)	Kappa	Exatidão global (%)	Kappa	Exatidão global (%)
Todas as conversões	0,5358 ^d	71,12	0,5519 ^e	72,14	0,5405 ^d	71,59
Agrupamento 1	0,6482 ^f	78,39	0,6500 ^f	78,59	0,6513 ^f	78,69
Agrupamento 2	0,7027 ^g	82,08	0,7048 ^g	82,21	0,7012 ^g	82,09

^{d,e,f,g} : Valores com mesmo índice segundo o teste Z, a 5% de significância.

¹ Função kernel de base radial

Na análise da matriz de confusão da classificação com todas as conversões, observou-se que CP, CA e AP apresentaram elevada confusão com outras classes (Tabela 5a). Na matriz de confusão do agrupamento 1, todas as classes apresentaram bom desempenho satisfatório (Tabela 5b). Na matriz de confusão do agrupamento 2, o grupo C (CA e AC) apresentou fraco desempenho classificatório, com elevada confusão com as áreas de não-mudança (Tabela 5c). Contudo, as conversões CP, CA e AP tiveram um fraco desempenho isoladamente mas quando agrupadas em TBPB apresentaram bom desempenho. Observou-se que a menor confusão entre classes ocorreu no agrupamento 1, apesar de apresentar índice *Kappa* inferior ao agrupamento 2 (não significativo).

A avaliação estatística dos valores *Kappa*, de acordo com o teste Z, ao nível de significância de 5% (Tabelas 3 e 4), a observação das matrizes de confusão entre classes (Tabela 5) e a análise do *Kappa* condicional para cada classe (Tabela 6) indicam um melhor desempenho da classificação *Bhattacharyya*, utilizando as imagens-diferença das frações do MLME, agrupando as classes em função da perda e do ganho de biomassa (agrupamento 1). Dessa forma, essa classificação foi selecionada para melhor caracterizar a dinâmica de uso e cobertura da terra na região estudada (Figura 4).

DISCUSSÃO

Análise do vetor de mudança

As imagens AVM originadas a partir das imagens-fração (MLME) mostraram-se úteis na identificação e separabilidade das conversões com origem em áreas florestais, mas tiveram limitações nas conversões com origem em áreas previamente convertidas em usos agrícola e pecuário, principalmente aquelas que envolviam as classes agricultura e capoeira (AC e CA), em função do comportamento dessas conversões nas imagens AVM. As características dessas conversões nas imagens analisadas, em função da época do ano (final da estação chuvosa) e pelo tipo de cultura predominante (banana), apresentaram baixa variabilidade nos componentes do modelo, tendo comportamento semelhante inclusive com as áreas de não-mudança. As conversões AP e CP também não foram satisfatoriamente discriminadas pelos produtos AVM. Essa incapacidade de separar essas conversões pode ser explicada pela grande variabilidade espectral dessas classes de uso e cobertura da terra após a conversão florestal. A formulação do cálculo dessas imagens (magnitude, alfa e beta) tem relação com respostas das imagens-fração nas datas distintas, que podem não corresponder às feições de interesse (conversões). O valor de magnitude, por exemplo, é maior quanto maior for a diferença absoluta entre as imagens-fração; já o valor de alfa

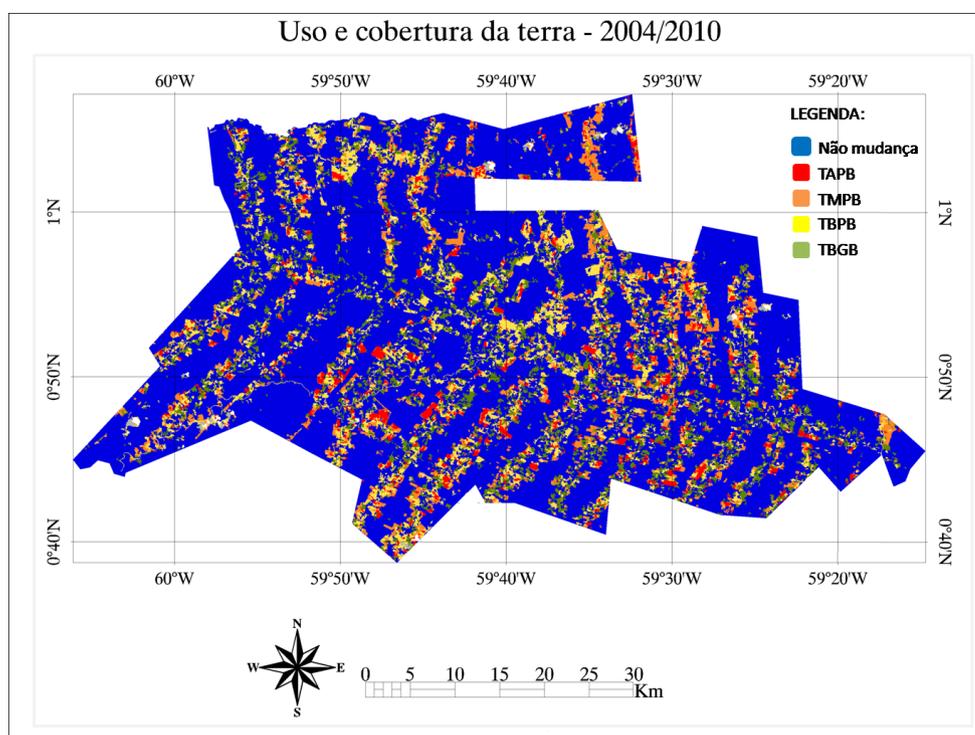


Figura 4 - Classificação temática das conversões pelo método *Bhattacharyya* com as imagens-diferença das frações do MLME, no período de 2004/2010. Classes da legenda: não mudança; TAPB: conversões de alta perda de biomassa; TMPB: conversões de média perda de biomassa; TBPB: conversões de baixa perda de biomassa; e TBGB: conversões de baixo ganho de biomassa. (figura colorida na versão eletrônica).

está relacionado com a razão entre a diferença das imagens-fração vegetação e a diferença das imagens-fração solo, tendo correspondência com diferenças sutis entre esses componentes, geralmente atribuídas ao ganho e perda de biomassa. O valor de beta tem relação com a diferença entre as imagens-fração sombra e o valor de magnitude.

Subtração das imagens-fração

Nesse ponto, a subtração simples das imagens-fração mostrou-se mais eficaz, gerando resultados mais satisfatórios e melhorando a separação de conversões como capoeira-agricultura (CA) e agricultura-capoeira (AC). Rogan *et al.* (2002) e Haertel *et al.* (2004) também utilizaram satisfatoriamente a subtração de imagens-fração como técnica de análise multitemporal de mudanças da cobertura vegetal. Lu *et al.* (2005) obtiveram bons resultados na detecção binária

de mudança utilizando técnicas de subtração de imagens (originais e transformadas).

Classificação supervisionada das conversões

No que se refere às classificações empregadas e a complementaridade entre os produtos AVM e da subtração entre imagens-fração, os resultados apontaram para a não-complementaridade significativa, uma vez que os valores *Kappa* não diferiram estatisticamente (teste Z) em função da junção dos seis produtos.

As classificações utilizando os agrupamentos propostos levaram a um significativo aumento nos valores *Kappa* e nos índices de exatidão global em relação às classificações das conversões isoladas. Isso é explicado principalmente pelas características semelhantes em relação às imagens-fração das conversões floresta-capoeira (FC) e floresta-agricultura (FA); capoeira-pasto (CP) e agricultura-pasto (AP); e capoeira-

Tabela 5 - Matrizes de confusão derivadas das classificações selecionadas, correspondentes a classificações com o algoritmo *Bhattacharyya*, tendo como classes: (a) todas as conversões; (b) agrupamento 1; (c) agrupamento 2.

(a)

	FC	FP	FA	CP	CA	PC	AP	AC	Não mudança
FC	55,00	0,00	7,27	0,00	0,00	0,00	0,00	0,00	0,00
FP	0,00	90,24	0,00	0,00	7,14	0,00	20,00	0,00	0,00
FA	45,00	0,00	90,91	0,00	14,29	0,00	0,00	0,00	0,00
CP	0,00	2,44	0,00	38,89	14,29	0,00	28,00	0,00	5,45
CA	0,00	0,00	0,00	0,00	42,86	5,88	0,00	6,25	1,82
PC	0,00	0,00	0,00	5,56	0,00	88,24	0,00	6,25	5,45
AP	0,00	4,88	0,00	38,89	0,00	0,00	44,00	0,00	5,45
AC	0,00	0,00	0,00	0,00	7,14	0,00	0,00	62,50	9,09
Não mudança	0,00	2,44	1,82	16,67	14,29	5,88	8,00	25,00	72,73
Exatidão global = 71,65%					Kappa = 0,6674 (Var = 1,02E-03)				

FC: floresta-capoeira; FP: floresta-pasto; FA: floresta-agricultura; CP: capoeira-pasto; CA: capoeira-agricultura; PC: pasto-capoeira; AP: agricultura-pasto; AC: agricultura-capoeira.

(b)

	TAPB	TMPB	TBPB	TBGB	Não mudança
TAPB	90,24	0,00	10,53	0,00	0,00
TMPB	0,00	98,67	3,51	0,00	0,00
TBPB	7,32	0,00	70,18	6,06	12,73
TBGB	0,00	0,00	1,75	75,76	14,55
Não mudança	2,44	1,33	14,04	18,18	72,73
Exatidão global = 82,76%			Kappa = 0,7804 (Var = 8,68E-04)		

TAPB: conversão de alta perda de biomassa (FP); TMPB: conversões de média perda de biomassa (FC e FA); TBPB: conversões de baixa perda de biomassa (CP, CA e AP); TBGB: conversões de baixo ganho de biomassa (PC e AC).

(c)

	GrupoA	GrupoB	GrupoC	GrupoD	Não mudança
GrupoA	98,67	0,00	6,67	0,00	0,00
GrupoB	0,00	91,67	10,00	0,00	10,91
GrupoC	0,00	0,00	53,33	5,88	12,73
GrupoD	0,00	1,19	3,33	88,24	3,64
Não mudança	1,33	7,14	26,67	5,88	72,73
Exatidão global = 85,06%			Kappa = 0,8007 (Var = 8,29E-04)		

Grupo A: conversões relacionadas a desmatamento (FC e FA); Grupo B: conversões do aumento da atividade pecuária (FP, CP e AP); Grupo C: conversões do pousio agrícola (CA e AC); Grupo D: conversão relativa à diminuição da atividade pecuária (PC).

Tabela 6 - Valores de *Kappa* condicional* para cada classe derivada dos agrupamento 1 e 2, nas classificações com o algoritmo *Bhattacharyya*.

Agrupamento 1			Agrupamento 2		
Classe	Kappa	Var (Kappa)	Classe	Kappa	Var (Kappa)
TAPB	0,8344609	3,74E-03	GrupoA	0,96307	6,52E-04
TMPB	0,963073	6,52E-04	GrupoB	0,84568	2,17E-03
TBPB	0,7047511	5,02E-03	GrupoC	0,62338	1,11E-02
TBGB	0,6969814	6,96E-03	GrupoD	0,77481	9,69E-03
NM	0,638	5,08E-03	NM	0,638	5,08E-03

*referente ao erro de exatidão do usuário (Congalton e Green 2009)

TAPB: conversão de alta perda de biomassa (FP); TMPB: conversões de média perda de biomassa (FC e FA); TBPB: conversões de baixa perda de biomassa (CP, CA e AP); TBGB: conversões de baixo ganho de biomassa (PC e AC); Grupo A: conversões relacionadas a desmatamento (FC e FA); Grupo B: conversões do aumento da atividade pecuária (FP, CP e AP); Grupo C: conversões do pousio agrícola (CA e AC); Grupo D: conversão relativa à diminuição da atividade pecuária (PC); NM = não mudança.

agricultura (CA) e agricultura-capoeira (AC). Quando agrupadas, essas conversões diminuem consideravelmente a confusão entre classes, melhorando o desempenho classificatório das novas classes.

Apesar de o agrupamento 2 apresentar maiores valores *Kappa* e maiores índices de exatidão global em relação ao agrupamento 1, a classe Grupo C (CA e AC) apresentou baixo valor de *Kappa* condicional, em função da elevada confusão com as áreas de não-mudança. Em menor intensidade, no agrupamento 1, a classe TBGB (PC e AC) foi a que apresentou o menor valor de *Kappa* condicional, também com elevada confusão com as áreas de não-mudança (Tabela 6). A justificativa para os fracos desempenhos dessas classes pode ser atribuída às características das conversões CA, PC e AC, que apresentaram pouca alteração em relação aos valores das imagens-fração. Esses resultados mostram a importância que assume a definição de um limiar de mudança entre as classes estabelecidas ao se empregar essa metodologia, conforme salientam diversos autores (Rogan *et al.* 2002; Chen *et al.* 2003; Lu *et al.* 2005).

Os resultados positivos estão ligados ao bom desempenho das classificações empregadas em identificar algumas conversões isoladamente, potencializado quando tais conversões são agrupadas em classes que têm relação com diferentes graus de perda e ganho de biomassa ou então quando agrupadas em classes com significado alinhado aos processos que ocorrem em áreas de fronteira agrícola.

O classificador por regiões *Bhattacharyya* apresentou desempenho superior em relação ao algoritmo *Support Vector Machine* na discriminação das conversões. A utilização das imagens-diferença das frações do MLME apresentou qualidade de classificação considerada muito boa a excelente, de acordo com o índice *Kappa* obtido (0,78 e 0,80), para os agrupamentos 1 e 2, respectivamente (Landis e Koch 1977). Em função da análise do *Kappa* condicional, o agrupamento 1 foi considerado superior na caracterização da dinâmica de uso e cobertura da terra na região estudada.

CONCLUSÕES

O procedimento metodológico utilizado no presente trabalho mostra potencial para investigação em outras áreas da Amazônia, uma vez que a melhoria da identificação, qualificação e quantificação do uso da terra é uma demanda de diversos setores que atuam na região (gestão, pesquisa, planejamento territorial etc). A abordagem histórica da dinâmica das mudanças ocorridas, através da análise das conversões de uso e cobertura da terra, pode contribuir para o melhor entendimento dos diferentes processos de ocupação e consequentemente para a elaboração de políticas públicas voltadas para as peculiaridades locais.

AGRADECIMENTOS

Os autores agradecem ao Sistema de Pós-Graduação da Embrapa e ao Instituto Nacional de Pesquisas Espaciais pelo suporte financeiro e técnico para a execução dessa pesquisa; à Embrapa Roraima pela infraestrutura física e logística para a realização do levantamento em campo; e aos revisores e ao editor da *Acta Amazonica* por seus valiosos comentários e sugestões.

BIBLIOGRAFIA CITADA

- Adams, J.B.; Sabol, D.E.; Kapos, V.; Almeida Filho, R.; Roberts, D.A.; Smith, M.O.; Gillespie, A.R. 1995. Classification of multispectral images based on fractions of endmembers: application to land-cover change in the Brazilian Amazon. *Remote Sensing of Environment*, 2:137-154.
- Barbosa, R.I. 1997. Distribuição das chuvas em Roraima. In: Barbosa, R.I.; Ferreira, E.J.G.; Castellón, E.G. (Ed.). *Homem, Ambiente e Ecologia no Estado de Roraima*. Instituto Nacional de Pesquisas da Amazônia, Manaus, Amazonas, p.325-335.
- Barros, N.C.C. 1995. *Roraima: paisagens e tempo na Amazônia Setentrional*. Editora Universitária (UFPE), Recife, 269 p.
- Boardman, J. W.; Kruse, F. A., and Green, R. O. 1995. Mapping target signatures via partial unmixing of AVIRIS data. *Summaries, Fifth JPL Airborne Earth Science Workshop*, JPL Publication 95-1, 1: 23-26.

- Canty, M.J.; Nielsen, A.A.; Schmidt, M. 2004. Automatic radiometric normalization of multitemporal satellite imagery. *Remote Sensing of Environment*, 91: 441-451.
- Canty, M.J.; Nielsen, A.A. 2008. Automatic radiometric normalization of multitemporal satellite imagery with iteratively re-weighted MAD transformation. *Remote Sensing of Environment*, 112: 1025-1036.
- Castillo, E.M. 2011. *Uso e cobertura da terra numa região agrícola de cerrado, via análise por vetor de mudança em imagens Landsat multitemporais*. Dissertação de Mestrado. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, São Paulo. 121p.
- Chen, J.; Gong, P.; He, C.; Pu, R.; Shi, P. 2003. Land-use/land-cover change detection using improved change-vector analysis. *Photogrammetric Engineering & Remote Sensing*, 4: 369-379.
- Companhia de Pesquisa de Recursos Minerais (CPRM). 2003. Zoneamento Ecológico-Econômico da Região Central do Estado de Roraima: Tomo III – Informações temáticas. CPRM/SEPLAN-RR. Diagnóstico do Meio Físico.
- Congalton, R.G.; Green, K. 2009. *Assessing the accuracy of remotely sensed data: Principles and Practices*. 2.ed. Boca Raton: CRC Press, 292p.
- Coppin, P.; Jonckheere, I.; Nackaerts, K.; Muys, B. 2004. Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 9: 1565-1596.
- EMBRAPA, 1999. *Sistema Brasileiro de Classificação dos Solos*. Brasília: Embrapa Produção da Informação; Rio de Janeiro: Embrapa Solos. 412p.
- Graça, P.M.L.A. 2004. *Monitoramento e caracterização de áreas submetidas à exploração florestal na Amazônia por técnicas de detecção de mudanças*. Tese de Doutorado. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, São Paulo. 275p.
- Haertel, V.; Shimabukuro, Y.E.; Almeida-Filho, R. 2004. Fraction images in multitemporal change detection. *International Journal of Remote Sensing*, 23: 5473-5489.
- IBGE, 2005. Mapa Exploratório de Solos (derivado da recuperação dos dados originais do Projeto RADAMBRASIL). Escala: 1:1.000.000. (www.ibge.gov.br/mapas_ibge/tem_solos.php). Acesso em: 31/03/2010.
- IBGE, 2005. Mapa de Vegetação (derivado da recuperação dos dados originais do Projeto RADAMBRASIL). Escala: 1:1.000.000. (www.ibge.gov.br/mapas_ibge/tem_vegetacao.php). Acesso em: 31/03/2010.
- INPE, 2008. Monitoramento da Cobertura Florestal da Amazônia por satélites – Sistemas PRODES, DETER, DEGRAD e QUEIMADAS. (www.obr.inpe.br/prodes/Relatorio_Prodes2008). Acesso em: 15/10/2009.
- Johnson, R. D.; Kasischke, E. S. 1998. Change vector analysis: a technique for the multispectral monitoring of land cover and condition. *International Journal of Remote Sensing*, 3:411-426.
- Lambin, E. F.; Strahler, A. H. 1994. Change Vector Analysis in multitemporal space: a tool to detect and categorize land cover change processes using high temporal resolution satellite data. *Remote Sensing of Environment*, 48: 231-244.
- Landis, J. R.; Koch, G. C. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 1:159-174.
- Lorena, R.B.; Santos, J.R.; Shimabukuro, Y.E. 2004. Técnica de detecção de mudanças aplicada em imagens de satélite como ferramenta de monitoramento de uso e cobertura da terra na Amazônia Ocidental (Acre). *Espaço e Geografia*, 7:47-76.
- Lu, D.; Moran, E.; Batistella, M. 2003. Linear mixture model applied to Amazonian vegetation classification. *Remote Sensing of Environment*, 4:456-469.
- Lu, D.; Mausel, P.; Batistella, M.; Moran, E. 2005. Land-cover binary change detection methods for use in the moist tropical region of the Amazon: a comparative study. *International Journal of Remote Sensing*, 1:101-114.
- Malila, W. A. 1980. Change Vector Analysis: an approach for detecting forest changes with Landsat. In: Machine Processing of Remotely Sensed Data Symposium, Purdue University, West Lafayette, Indiana. *LARS Proceedings*, 326-335.
- Mather, P.M. 1999. *Computer processing of remotely-sensed images: an introduction*. 2.ed. Chichester: John Wiley, 1999, 292p.
- Matthew, M.W.; Adler-Golden, S.M.; Berk, A.; Felde, G.; Anderson, G.P.; Gorodetzky, D.; Paswaters, S.; Shippert, M. 2003. Atmospheric correction of spectral imagery: evaluation of the FLAASH algorithm with AVIRIS data. In: Algorithms and Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery IX. *SPIE Proceedings*, 5093: 474-482.
- Mourão, G.M.N. 2008. Colonização recente no sudeste de Roraima, Amazônia Brasileira: entre a política e a natureza. *Acta Geografica*, 4: 31-39.
- Nielsen, A.A. 2007. The regularized iteratively reweighted MAD method for change detection in multi- and hyperspectral data. *IEEE Transactions on Image Processing*, 16: 463-478.
- Ponzoni, F.J.; Zullo Junior, J.; Lamparelli, R.A.C. 2007. *Calibração absoluta de sensores orbitais: conceituação, principais procedimentos e aplicação*. São José dos Campos, SP: Ed. Parêntese, 65p.
- R Development Core Team. 2011. R: *a language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, (www.R-project.org).
- Richards, J.A.; Jia, X. 2006. *Remote sensing digital image analysis: An introduction*. 4 ed. Springer, Berlin, 476 p.
- Roberts, D. A.; Batista, G. T.; Pereira, J. L. G.; Waller, E. K.; Nelson, B. W. 1998. Change identification using multitemporal spectral mixture analysis: applications in eastern Amazonia. In: Lunetta, R.S; Elvidge, C.D. (ed.) *Remote sensing change detection: environmental monitoring methods and applications*. Ann Arbor: Ann Arbor Press, p.137-161.
- Rogan, J.; Franklin, J.; Roberts, D.A. 2002. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote Sensing of Environment*, 80: 143-156.
- Schoenmakers, R.P.H.M.; Wilkinson, G.G.; Schoauten, T.E. 1991. Segmentation of remotely-sensed images: a redefinition for operational applications. In: International Geoscience and Remote Sensing Symposium (IGARSS'91), Espoo, Finland. *Proceedings*, 1: 1087-1090.

- Shimabukuro, Y.E.; Smith, J.A. 1991. The least-square mixing models to generate fraction images derived from remote sensing multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 29: 16-20.
- Shimabukuro, Y.E.; Batista, G.T.; Mello, E.M.K.; Moreira, J.C.; Duarte, V. 1998. Using shade fraction image segmentation to evaluate deforestation in Landsat Thematic Mapper images of the Amazon Region. *International Journal of Remote Sensing*, 3:535-541.
- Silva, P.G. ; Santos, J.R.; Shimabukuro, Y.E.; Souza, P.E.U.; Graça, P.M.L.A. 2003. Change vector analysis technique to monitor selective logging activities in Amazon. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2003)*, 4: 2580-2582.
- Smith, M. O.; Ustin, S. L.; Adams, J. B.; Gillespie, A. R. 1990. Vegetation in deserts: a regional measure of abundance from multispectral images. *Remote Sensing of Environment*, 1: 1-26.
- Sousa, B.F.S.; Teixeira, A.S.; Silva, F.A.T.F.; Andrade, E.M.; Braga, A.P.S. 2010. Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma caatinga. *Revista Brasileira de Cartografia*, 62: 385-399.

Recebido em 30/10/2012

Aceito em 20/03/2013