

Detecção da Infraestrutura para Exploração Florestal em Rondônia Utilizando Dados de Sensoriamento Remoto

Ekena Rangel Pinagé^{1,2}, Eraldo Aparecido Trondoli Matricardi²

¹Embrapa Monitoramento por Satélite, Campinas/SP, Brasil

²Departamento de Engenharia Florestal, Universidade de Brasília – UnB, Brasília/DF, Brasil

RESUMO

A infraestrutura para exploração florestal é fundamental nas atividades de exploração madeireira, mas responde por grande parte dos impactos ambientais dessa atividade. O presente estudo aplicou e testou cinco técnicas de processamento digital de imagens orbitais com três resoluções espaciais distintas para a detecção de estradas e pátios florestais construídos em áreas sob manejo florestal sustentável na Floresta Nacional do Jamari, estado de Rondônia. Os resultados mostraram que o NDVI e a Análise de componentes principais apresentaram a melhor acurácia global nas resoluções espaciais de 5 e 10 metros e na de 30 metros, respectivamente. De maneira geral, a acurácia do produtor para a classe de interesse não foi alta, alcançando no máximo 39,2%, e índice *Kappa* de 0,38. A baixa performance das técnicas de geoprocessamento utilizadas na detecção de florestas exploradas seletivamente está relacionada às alterações ocorridas no dossel da floresta manejada, pouco perceptíveis em imagens de satélite.

Palavras-chave: sensoriamento remoto, manejo florestal sustentável, processamento digital de imagens.

Detection of Logging Infrastructure in the State of Rondônia Using Remotely Sensed Data

ABSTRACT

Logging lands (forest roads and log decks) are an underlying issue during selective logging activities, but they are responsible for most impacts on the forest. This study aimed to apply and assess the performance of five geoprocessing techniques on remotely sensed data using three different spatial resolutions to detect logging lands under forest management at the Jamari National Forest, state of Rondônia, Brazil. The research results showed that Normalized Difference Vegetation Index (NDVI) and Principal Components Analysis (PCA) presented the best overall accuracy using spatial resolutions of 5 and 10 meters, and 30 meters, respectively. Generally, the overall accuracy and Kappa statistics for the selectively logged forest classifications were not good (39.2% or lower, and 0.38 or lower, respectively). The low performance of the geoprocessing techniques is related to the subtle changes on the forest canopy cover under selective logging activities.

Keywords: remote sensing, sustainable forest management, digital image processing.

1. INTRODUÇÃO E OBJETIVO

Para que o manejo florestal seja praticado, é necessária a abertura da infraestrutura florestal permanente, constituída de pátios de estocagem, estradas primárias e secundárias, além das pontes. Porém, a sustentabilidade da atividade demanda que as vias de acesso gerem o menor impacto possível aos ecossistemas. De acordo com um levantamento do IFT (2011), obras de infraestrutura como estradas e pátios podem impactar diretamente até 10% da área onde se pratica o manejo florestal. Quando as estradas não são bem construídas, podem provocar prejuízos aos recursos naturais, afetando qualidade da água, migração e deslocamento de espécies, ocasionando ainda fragmentação de habitats e erosão do solo (Uhl & Vieira, 1989).

A infraestrutura florestal é o principal elemento de contexto do padrão espacial do corte seletivo de madeira, constituída por estradas primárias que dão acesso à área de manejo e estradas secundárias ligando pátios de estocagem. Geralmente, esses elementos podem ser detectados em imagens de satélite, possibilitando o mapeamento da exploração madeireira por sensoriamento remoto.

Uma vez que há limitações para a detecção do impacto de outras operações da exploração florestal com o uso de imagens ópticas, tais como abate e arraste de árvores (Coops et al., 2007), a infraestrutura foi selecionada como objeto da avaliação da qualidade do mapeamento do corte seletivo de madeira a partir de dados orbitais.

O objetivo desta análise é aplicar e testar a detecção da infraestrutura florestal utilizando diferentes técnicas de processamento de imagens de satélite com diferentes resoluções espaciais. Os testes de detecção da infraestrutura foram realizados com a aplicação de algumas técnicas de processamento digital de imagens em três resoluções espaciais distintas: o Modelo Linear de Mistura Espectral (MLME), técnica mais utilizada atualmente nesse tipo de detecção, com imagens de média resolução espacial (Souza et al., 2005; Asner et al., 2005; Matricardi et al., 2010); alguns índices de vegetação: o NDVI, por ser o índice mais utilizado (Rouse et al., 1973), o MSAVI, por ter correção para os efeitos do solo (Qi et al., 1994), e o GEMI, por apresentar correção

para os efeitos atmosféricos (Pinty & Verstraete, 1992); e a Análise de componentes principais (ACP).

As técnicas e testes foram aplicados na área de floresta pública sob concessão federal na Floresta Nacional (Flona) do Jamari, Estado de Rondônia, onde existem planos de manejo florestal sustentável em execução desde 2010.

2. MATERIAL E MÉTODOS

2.1. Área de estudo

A Flona do Jamari é uma Unidade de Conservação de Uso Sustentável criada em 25 de setembro de 1984. Situa-se nos municípios de Itapuã do Oeste, Cujubim e Candeias do Jamari, no estado de Rondônia, com área de 220 mil hectares (Figura 1). Segundo o plano de manejo da unidade, a tipologia vegetal predominante é a Floresta Ombrófila Densa com porções de Floresta Ombrófila Aberta, que podem se apresentar com predominância de palmeiras ou com cipós, de acordo com a classificação fisionômica-ecológica do IBGE (2012).

Em 2008, a Flona do Jamari destinou uma área de 96 mil hectares para concessão florestal, dividida em três unidades de manejo, o que a tornou a primeira Floresta Nacional a passar por esse tipo de licitação no Brasil.

Nesse trabalho foram consideradas como área de estudo as Unidades de Produção Anual (UPA) 1 das Unidades de Manejo Florestal (UMF) 1 e 2, áreas delimitadas em amarelo na Figura 1. A área da UPA 1 na UMF 1 tem 594 hectares e a área da UPA 1 na UMF 2, 1.068 hectares. O volume médio de madeira retirado foi de 14,8 m³.ha⁻¹ na área da UMF 1 e de 9,6 m³.ha⁻¹ na área da UMF 2.

2.2. Imagens de satélite e técnicas de processamento

Foram utilizadas imagens multiespectrais do satélite Landsat 5, sensor TM, largamente utilizadas no monitoramento da Amazônia (INPE, 2006) e atualmente distribuídas gratuitamente. Além desse motivo, o Landsat 5 é o único satélite da série Landsat operacional nas datas escolhidas para a análise. Foram

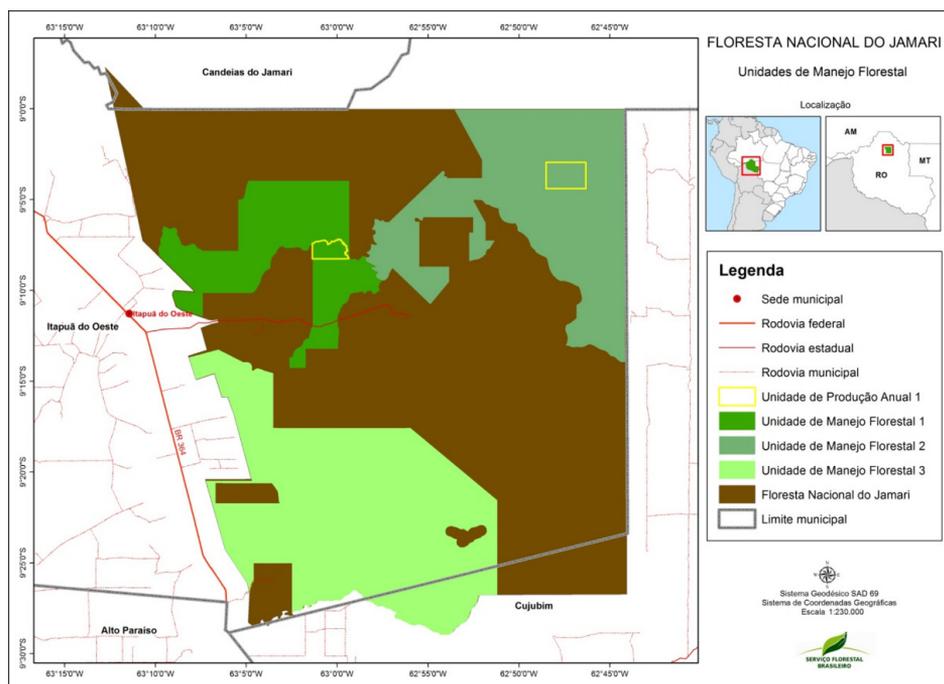


Figura 1. Localização da Floresta Nacional do Jamari, de suas Unidades de Manejo Florestal (UMF) e das Unidades de Produção Anual (UPA) objetos deste estudo.

Figure 1. Study site location at the Jamari National Forest, its Forest Management Plots (FMP), and the Annual Production Plots (APP) in this study.

testadas também ortoimagens da constelação de satélites RapideEye, no nível de processamento 3A.

As imagens de satélite que cobrem a área de estudo foram adquiridas em duas coberturas distintas: uma antes do início da exploração florestal na área, que ocorreu em setembro de 2010, e outra após o início, em maio de 2011. Três resoluções espaciais foram utilizadas: as imagens RapidEye em sua resolução de ortoimagens (5 metros) e reamostradas para 10 metros, e a imagem Landsat 5 TM com 30 metros. A Tabela 1 mostra as informações das imagens Landsat e RapidEye utilizadas.

As imagens Landsat passaram por calibração radiométrica – conversão de valores digitais para níveis de radiância e, posteriormente, para valores de reflectância no topo da atmosfera e, em seguida, por correção geométrica. As imagens RapidEye passaram apenas pela correção radiométrica, por serem disponibilizadas já com a correção geométrica. A partir das imagens calibradas para reflectância no topo da atmosfera, as técnicas de processamento digital de imagens detalhadas a seguir foram aplicadas.

Tabela 1. Dados de sensoriamento remoto utilizado neste estudo.

Table 1. Remotely sensed data used in this study.

Satélite/ Constelação	Órbita-ponto/ Tile	Data de aquisição
Landsat5	232/066	15/5/2010
Landsat5	232/066	5/7/2011
RapidEye	2034814	14/5/2010
RapidEye	2034815	14/5/2010
RapidEye	2034915	14/5/2010
RapidEye	2034916	10/5/2010
RapidEye	2034814	31/5/2011
RapidEye	2034815	31/5/2011
RapidEye	2034915	31/5/2011
RapidEye	2034916	31/5/2011

2.2.1. Normalized Difference Vegetation Index (NDVI)

O NDVI foi um dos primeiros índices de vegetação desenvolvidos e é amplamente utilizado até os dias atuais, tendo sido explorado em diferentes abordagens em

estudos agrícolas, florestais e climáticos. Desenvolvido por Rouse et al. (1973), deu origem a vários outros índices, que são transformações do NDVI, na tentativa de reduzir os efeitos do solo e da atmosfera e melhorar o desempenho dos índices de vegetação na avaliação da vegetação. Sua fórmula é descrita na Equação 1:

$$NDVI = (\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V) \quad (1)$$

em que ρ_{IVP} = Reflectância na faixa espectral do infravermelho próximo e ρ_V = Reflectância na faixa espectral do vermelho.

2.2.2. Modified Soil Adjusted Vegetation Index (MSAVI)

Desenvolvido por Qi et al. (1994), o MSAVI oferece uma fórmula com a inclusão de um fator de correção para a influência dos solos, L , que depende da cobertura vegetal da área de trabalho. Sua fórmula é mostrada nas Equações 2 e 3:

$$MSAVI = ((\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V + L)) * (1 + L) \quad (2)$$

em que ρ_{IVP} = Reflectância na faixa espectral do infravermelho próximo; e ρ_V = Reflectância na faixa espectral do vermelho; e

$$L = ((\rho_{IVP} - \rho_V) * s + 1 + \rho_{IVP} + \rho_V)^2 - 8.0 * s * (\rho_{IVP} - \rho_V) \quad (3)$$

em que s = Declividade da linha de solos calculada a partir da reflectância do solo exposto na imagem RapidEye.

2.2.3. Global Environment Monitoring Index (GEMI)

Considerando que a influência da atmosfera é maior na faixa espectral do vermelho do que na do infravermelho próximo, Pinty & Verstraete (1992) propuseram para o monitoramento global da vegetação esse novo índice, o GEMI, criado para minimizar a influência dos efeitos atmosféricos no valor final do índice. Seu cálculo é dado pelas Equações 4 e 5:

$$GEMI = \eta(1 - 0,25\eta) * ((\rho_V - 0,125) / (1 - \rho_V)), \quad (4)$$

em que ρ_V = Reflectância na faixa espectral do vermelho; e

$$\eta = 2 * (((\rho_{IVP}^2 - \rho_V^2) + 1,5\rho_{IVP} + 0,5\rho_V) / (\rho_{IVP} + \rho_V + 0,5)) \quad (5)$$

onde ρ_{IVP} = Reflectância na faixa espectral do infravermelho próximo; e ρ_V = Reflectância na faixa espectral do vermelho.

2.2.4. Modelo linear de mistura espectral (MLME)

Dentro de um único pixel podem estar incluídos diferentes objetos ou elementos da cobertura da superfície terrestre. Isso gera uma mistura espectral, ou seja, a resposta espectral de um pixel da imagem é resultante da combinação da resposta espectral dos diferentes componentes que formam esse pixel.

Com o uso do Modelo linear de mistura espectral é possível estimar a proporção de cada um desses alvos no pixel a partir da aplicação da técnica de otimização dos mínimos quadrados (Shimabukuro & Smith, 1991). Com a aplicação desse modelo é gerada uma imagem fração para cada um dos componentes considerados, conhecidos como endmembers. Essas imagens representam as proporções (abundância) de cada um dos respectivos componentes da cena selecionados para o modelo de mistura espectral (Ponzoni & Shimabukuro, 2009).

2.2.5. Análise de componentes principais (ACP)

A correlação entre bandas é um problema frequentemente encontrado em imagens multiespectrais. A transformação por componentes principais é uma técnica utilizada para reduzir essa redundância entre os dados presentes nas diferentes faixas espectrais. O propósito dessa técnica é comprimir toda a informação contida em um conjunto original de dados com n bandas para um dado com menos do que n bandas, que pode então ser utilizado no lugar do dado original (Lillesand et al., 2008). Eliminar a alta correlação das imagens tem a vantagem de reduzir o volume de dados a ser analisado e de redistribuir a informação espectral entre as novas principais componentes (Meneses & Almeida, 2012).

2.2.6. Análise de acurácia

A análise estatística da detecção da infraestrutura florestal consistiu na avaliação de acurácia das classificações geradas com as cinco técnicas de processamento digital de imagens descritas anteriormente. Nessa avaliação é gerada para cada classificação uma matriz de confusão (também conhecida como tabela de contingência) com dois dados: aqueles gerados pela classificação e pontos de GPS coletados em campo com um receptor GPS de navegação, adotados como dado de referência para a

validação. Esse procedimento é descrito em detalhes por Congalton & Green (2008).

Foram analisadas as estatísticas fornecidas pela matriz de confusão: índice Kappa, erros de omissão e comissão e acurácia global, do produtor e do usuário. O índice Kappa representa a medida da concordância entre os dados de referência e os dados da classificação (indicados pela diagonal da matriz de confusão) e da concordância esperada ao acaso (indicada pelas marginais da matriz de confusão). A acurácia global representa a proporção dos pontos de referência corretamente classificados (Congalton & Green, 2008).

Um fluxograma resumindo as etapas seguidas para a detecção da infraestrutura florestal é apresentado na Figura 2.

3. RESULTADOS E DISCUSSÃO

A configuração das estradas e pátios de estocagem bem como as árvores abatidas até a data de aquisição das imagens auxiliam na interpretação dos resultados das classificações geradas (Figura 3). As classificações geradas a partir da aplicação das cinco técnicas nos três conjuntos de imagens mostraram resultados bastante

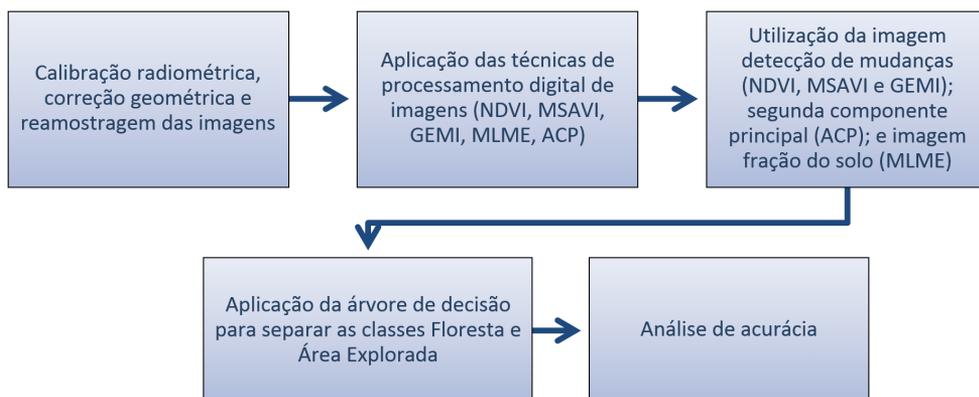


Figura 2. Fluxo utilizado na detecção da infraestrutura florestal utilizando dados de sensoriamento remoto. **Figure 2.** Flowchart for the logging infrastructure detection using remotely sensed data.

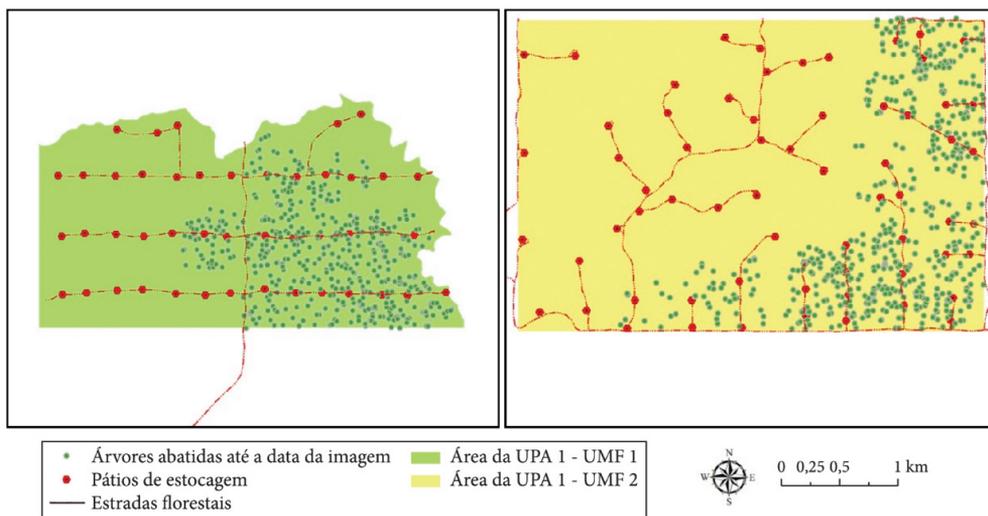


Figura 3. Infraestrutura florestal existente nas áreas de estudo e árvores abatidas até a data das imagens de satélite utilizadas.

Figure 3. Existing logging infrastructure in the study sites and harvested trees by the acquisition date of the satellite images.

discrepantes para as diferentes resoluções espaciais, especialmente entre as imagens RapidEye e Landsat, conforme mostram as matrizes de confusão dos dados gerados a partir das imagens RapidEye na resolução espacial de 5 metros e o mapa das classificações (Tabela 2 e Figura 3, respectivamente).

Para essa resolução houve uma variação de até 13% entre os resultados das cinco técnicas empregadas. O NDVI apresentou os melhores resultados de acurácia global e índice Kappa (70,01% e 0,38, respectivamente). O GEMI apresentou o pior desempenho entre os resultados obtidos para essa resolução, com 57,47% e 0,12 de acurácia global e índice Kappa, respectivamente.

As outras técnicas apresentaram resultados intermediários entre o NDVI e o GEMI, apresentando acurácia global e índice Kappa de: 63,34% e 0,24 (MLME); 62,75% e 0,23 (ACP); e 62,17% e 0,22 (MSAVI). As demais estatísticas geradas apresentadas na matriz de confusão também seguiram esse padrão.

Para a classe de interesse do mapeamento (área explorada), os valores de acurácia do produtor foram bem mais baixos, variando de 39,26% (NDVI) a 14,72% (GEMI). Já para a acurácia do usuário, os valores para a classe de interesse foram bem mais altos, sendo que somente os índices GEMI e MSAVI apresentaram valor inferior a 90%.

Tabela 2. Matrizes de confusão das cinco técnicas aplicadas nas imagens RapidEye com resolução espacial de 5 metros.

Table 2. Confusion matrices of the five processing techniques applied in *RapidEye* imagery with 5 meters spatial resolution.

Normalized Difference Vegetation Index (NDVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	175	99	274	98,31%	63,87%	36,13%	1,69%	70,01%	0,39
A. explorada	3	64	67	39,26%	95,52%	4,48%	60,74%		
Total	178	163	341	--	--	--	--		
Global Environmental Monitoring Index (GEMI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	172	139	311	96,63%	55,31%	44,69%	3,37%	57,47%	0,12
A. explorada	6	24	30	14,72%	80,00%	20,00%	85,38%		
Total	178	163	341	--	--	--	--		
Modified Soil Adjusted Vegetation Index (MSAVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	160	111	271	89,89%	59,04%	40,96%	10,11%	62,17%	0,22
A. explorada	18	52	70	31,90%	74,29%	25,71%	68,10%		
Total	178	163	341	--	--	--	--		
Análise de componentes principais (ACP)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	175	124	299	98,31%	58,53%	41,47%	1,69%	62,75%	0,23
A. explorada	3	39	42	23,93%	92,86%	7,14%	76,07%		
Total	178	163	341	--	--	--	--		
Modelo linear de mistura espectral (MLME)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	175	122	297	98,31%	58,92%	41,08%	1,69%	63,34%	0,24
A. explorada	3	41	44	25,15%	93,18%	6,82%	74,85%		
Total	178	163	341	--	--	--	--		

Esses valores de acurácia do produtor e do usuário indicam que o mapeamento da infraestrutura florestal foi conservador, com altas taxas de omissão para a classe área explorada, concentradas nas áreas de estradas secundárias. Essas feições são de difícil detecção, especialmente numa exploração de impacto reduzido como a que ocorre nas concessões florestais. Em muitos trechos elas não apresentam largura suficiente para abrir o dossel florestal e expor porções de solo, como acontece nas estradas primárias e pátios de estocagem.

Além da análise estatística obtida com a matriz de confusão, é pertinente também analisar visualmente o resultado das classificações. Comparando-se o NDVI com o GEMI, por exemplo, percebe-se que o NDVI mapeou melhor a infraestrutura e apresentou menos polígonos espúrios, sugerindo que ele foi mais eficiente na detecção da exploração florestal.

De maneira geral, as técnicas baseadas em índices de vegetação apresentaram mais polígonos classificados como infraestrutura florestal do que o MLME e a ACP. Mas, em contrapartida, essas técnicas apresentaram melhor configuração das estradas primárias e alguma sinalização de estradas secundárias, mesmo que incipiente e descontínua, especialmente o MSAVI. Apresentam ainda alguma indicação de impacto no dossel ocasionado pelas operações de derrubada e arraste das toras, especialmente o NDVI. A comparação do mapa da Figura 3 com a Figura 4 permite a identificação do impacto no dossel relacionado ao abate das árvores até a data de aquisição das imagens, que foi melhor mapeado nas classificações geradas com os índices de vegetação.

Para a resolução espacial de 10 metros, a acurácia global das diferentes técnicas apresentaram no máximo 5,2% de variação, menor do que a variação encontrada na resolução de 5 metros, como pode ser observado nas matrizes de confusão (Tabela 3).

O mapa das classificações geradas a partir das imagens RapidEye reamostradas para a resolução espacial de 10 metros mostra que as técnicas que não envolveram detecção de mudanças apresentaram resultados idênticos e, visualmente, seus resultados também são muito semelhantes (Figuras 4 e 5). O NDVI continuou apresentando melhor acurácia global e índice Kappa, assim como o GEMI, seguiu apresentando o pior desempenho.

Entretanto, dessa vez o MSAVI se mostrou a melhor técnica para a detecção da classe área explorada, com acurácia do produtor cerca de 5% maior que a do NDVI. A imagem resultante da aplicação dessa técnica é a que detém maior quantidade de pequenos polígonos da classe de interesse, então a chance de ocorrerem coincidências com os pontos de validação são maiores. Inversamente, mas pelo mesmo motivo, a acurácia do produtor da classe floresta para essa técnica foi a menor de todas.

Comparando-se os resultados obtidos com a resolução de 10 metros com os da de 5 metros, observa-se que apenas o NDVI apresentou resultado superior na resolução de 5 metros, as demais técnicas tiveram desempenho melhor na resolução de 10 metros. Esses resultados gerais indicam que não há ganho representativo em aumentar a resolução espacial de 10 para 5 metros. Visualmente, os resultados das duas resoluções também são bastante similares.

Na resolução de 30 metros, os resultados de acurácia global das cinco técnicas foram muito similares, com variação de aproximadamente 5% (Tabela 4). A técnica que apresentou o maior valor dessa estatística foi a ACP (57,72%); o NDVI e o MSAVI apresentaram resultados idênticos (53,64%). Entretanto, quando se analisa a acurácia do produtor para a classe área explorada, observa-se que os valores foram bem baixos (variando de 0,61% para o GEMI a 15,15% para a ACP). A acurácia global ficou em torno dos 50%, porque o mapeamento da classe floresta foi excelente para todas as técnicas, como pode ser verificado na matriz de confusão, dado que é uma classificação binária. Somente o resultado da Análise de componentes principais apresentou valor da estatística Kappa superior a 0,1, valor já considerado de baixa concordância (Congalton & Green, 2008).

Na análise visual da Figura 6 observa-se que apenas os resultados do MSAVI, da ACP e do MLME mostram alguma configuração das estradas primárias existentes, mesmo que descontínuas. Corroborando a maior acurácia global obtida entre as cinco técnicas, a ACP apresenta o resultado com maior significado real (no campo), principalmente na área da UMF 2. Silva et al. (2009) também identificaram a ACP, em comparação com o MLME e a transformação IHS com razão de bandas, como a melhor técnica na detecção

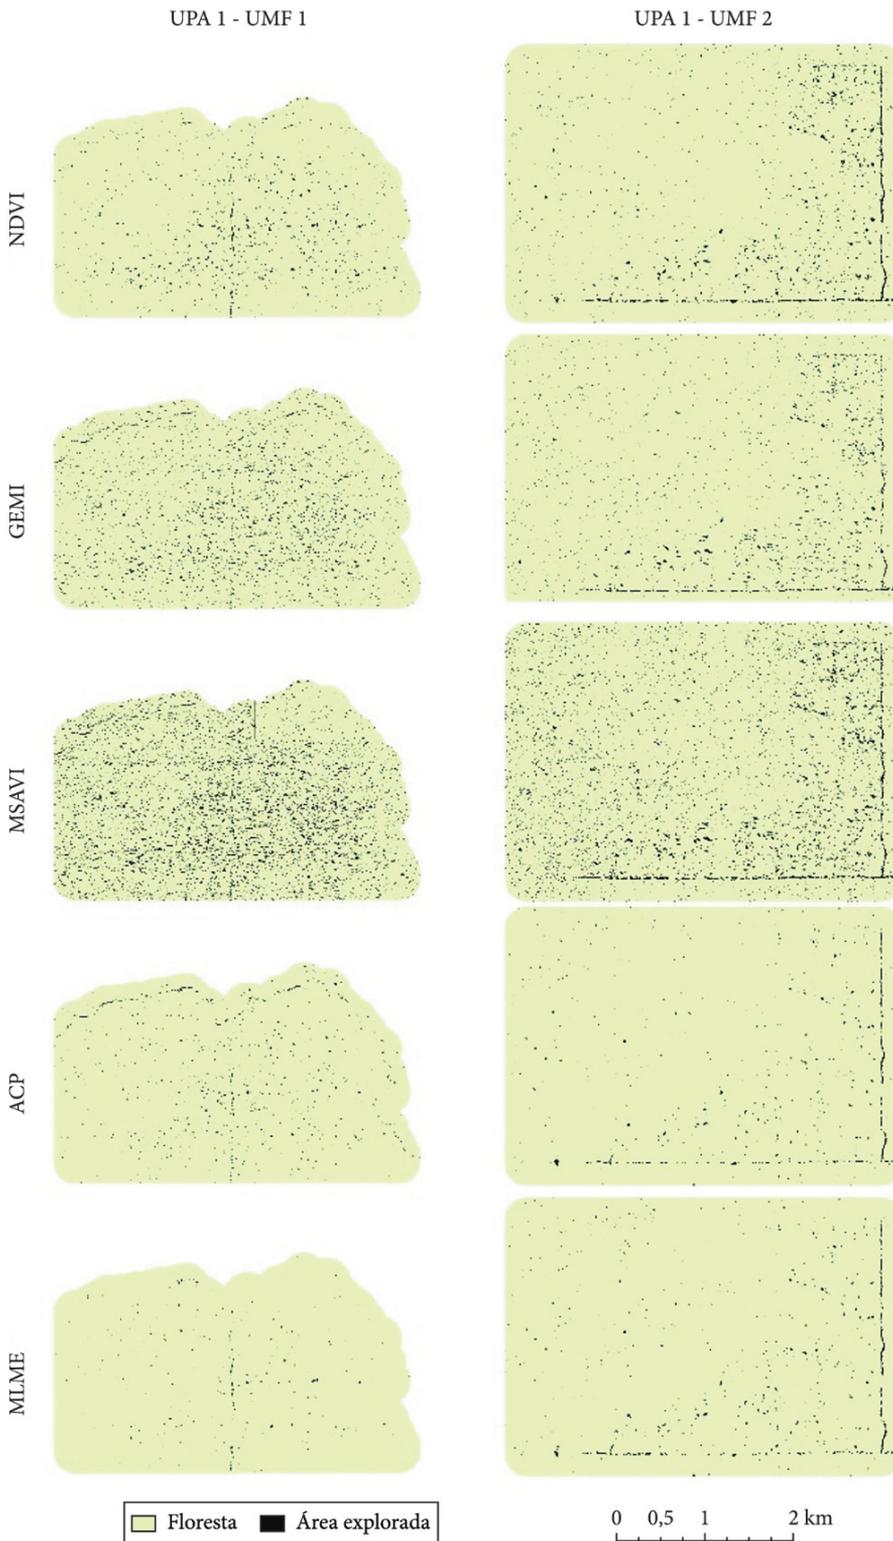


Figura 4. Resultados das classificações geradas com as cinco técnicas aplicadas nas imagens RapidEye com resolução espacial de 5 metros.

Figure 4. Results of the binary classifications derived from the five processing techniques applied in *RapidEye* imagery with 5 meters spatial resolution.

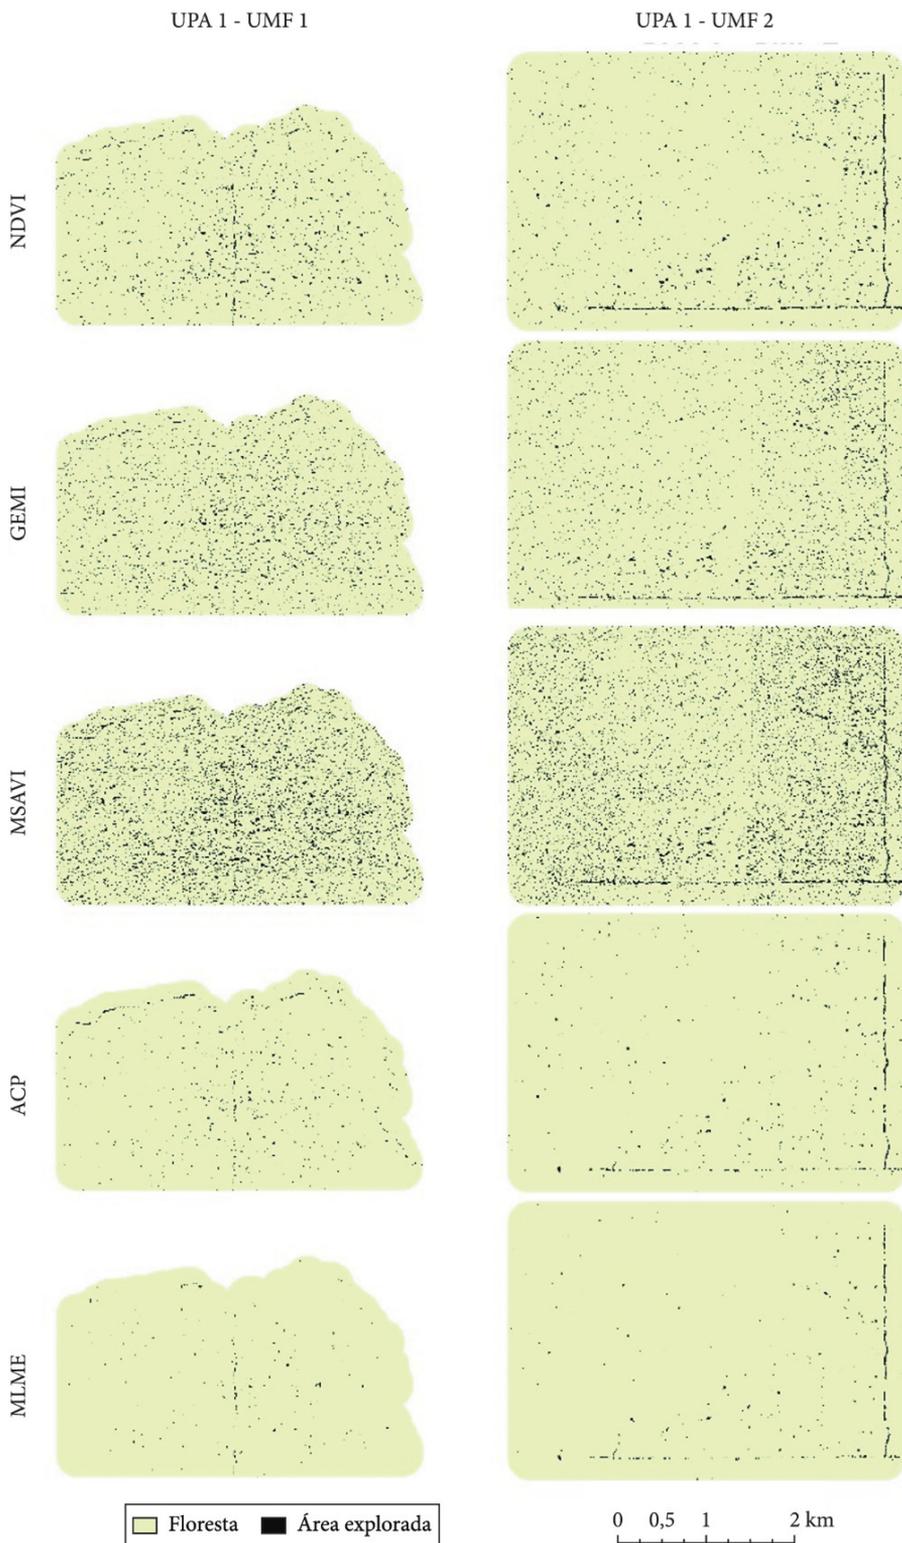


Figura 5. Resultados das classificações geradas com as cinco técnicas aplicadas nas imagens RapidEye com resolução espacial de 10 metros.

Figure 5. Results of the binary classifications derived from the five processing techniques applied in *RapidEye* imagery with 10 meters spatial resolution.

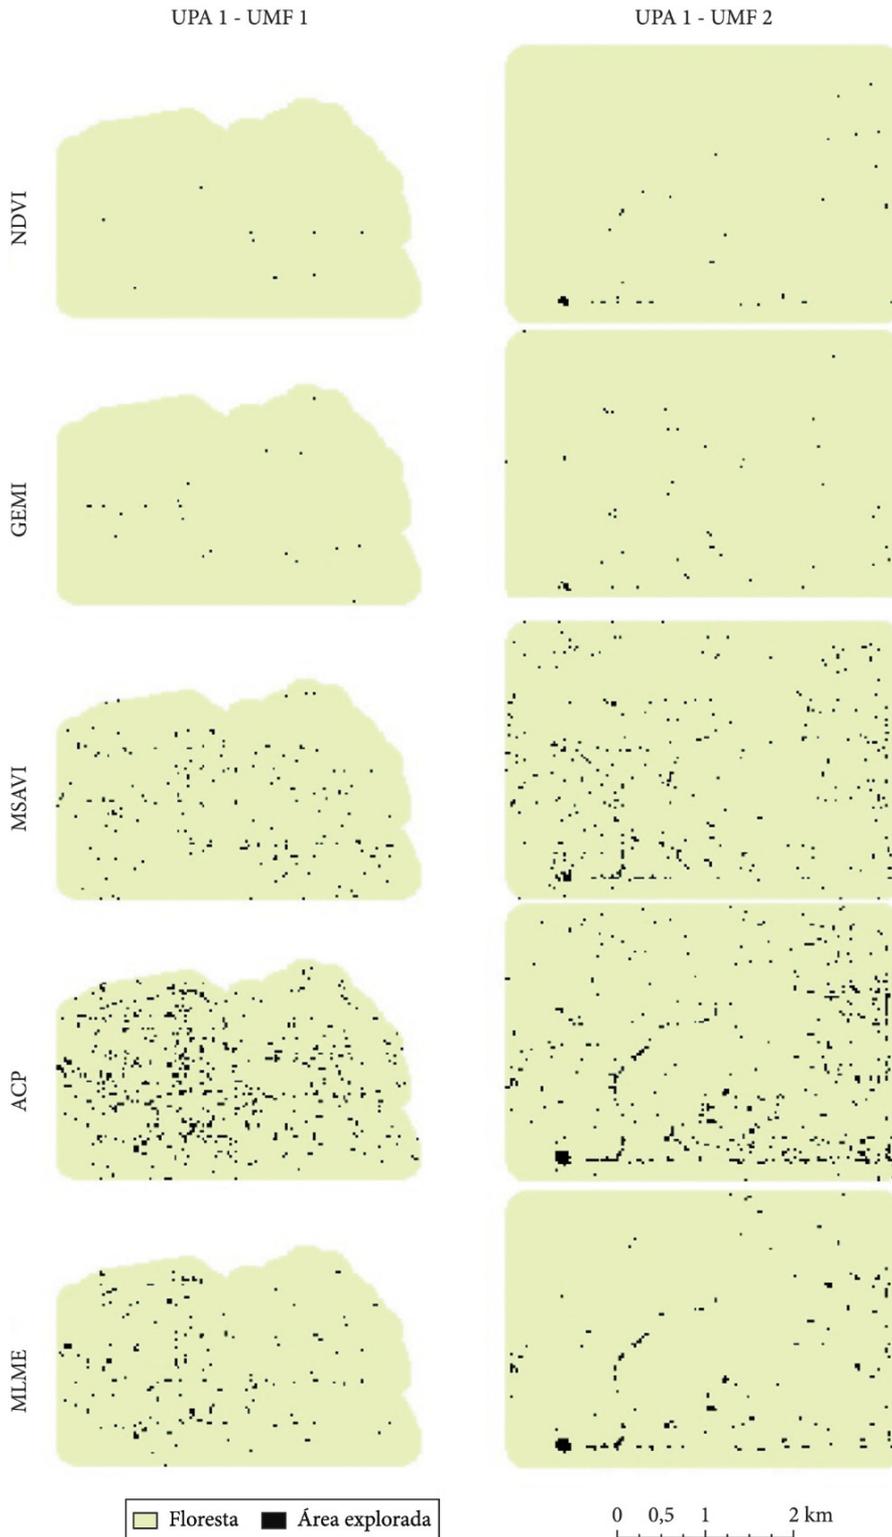


Figura 6. Resultados das classificações geradas com as cinco técnicas aplicadas nas imagens Landsat 5 TM com resolução espacial de 30 metros.

Figure 6. Results of the binary classifications derived from the five processing techniques applied in *Landsat 5 TM* imagery with 30 meters spatial resolution.

Tabela 3. Matrizes de confusão das cinco técnicas aplicadas nas imagens RapidEye com resolução espacial de 10 metros.**Table 3.** Confusion matrices of the five processing techniques applied in *RapidEye* imagery with 10 meters spatial resolution.

Normalized Difference Vegetation Index (NDVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	171	109	280	96,07%	61,07%	38,93%	3,93%	65,98%	0,30
A. explorada	7	54	61	33,13%	88,52%	11,48%	66,87%		
Total	178	163	341	--	--	--	--		
Global Environmental Monitoring Index (GEMI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	168	124	292	94,38%	57,53%	42,47%	5,62%	60,70%	0,19
A. explorada	10	39	49	23,93%	79,59%	20,41%	76,07%		
Total	178	163	341	--	--				
Modified Soil Adjusted Vegetation Index (MSAVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	157	100	257	88,20%	61,09%	38,91%	11,80%	64,52%	0,27
A. explorada	21	63	84	38,65%	75,00%	25,00%	61,35%		
Total	178	163	341	--	--	--	--		
Análise de componentes principais (ACP)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	176	121	297	98,88%	59,26%	40,74%	1,12%	63,93%	0,25
A. explorada	2	42	44	25,77%	95,45%	4,55%	74,23%		
Total	178	163	341	--	--	--	--		
Modelo linear de mistura espectral (MLME)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	176	121	297	98,88%	59,26%	40,74%	1,12%	63,93%	0,25
A. explorada	2	42	44	25,77%	95,45%	4,55%	74,23%		
Total	178	163	341	--	--	--	--		

do corte seletivo com imagens Landsat 5 TM numa área do Mato Grosso.

Os baixos valores do índice Kappa sugerem que a detecção da infraestrutura florestal nas imagens Landsat tem pouca aderência aos dados de referência, que representam a realidade de campo. A extensão dos alvos em relação à resolução espacial das imagens explica esses resultados: muitos alvos apresentam dimensões menores que 30 metros, resolução espacial do sensor TM.

De maneira geral, considerando-se as três resoluções espaciais analisadas, esperava-se que os índices de vegetação com correção para os fatores atmosféricos (GEMI) e de influência do solo (MSAVI) apresentassem

melhor desempenho na classificação do que o NDVI, contudo isso não foi constatado. Uma possível causa para o melhor desempenho do NDVI é a data das imagens utilizadas na detecção da infraestrutura. As imagens RapidEye pós-exploração foram adquiridas em maio, já no início da estação seca. Se elas tivessem sido adquiridas no auge da estação chuvosa, a vegetação provavelmente estaria no seu vigor máximo e a saturação com vegetação densa que ocorre no NDVI poderia ter diminuído seu desempenho.

A acurácia da classe floresta elevou fortemente os valores da acurácia global para todas as classificações. Esse fato é evidenciado pela diferença entre os valores obtidos na acurácia global (dada em porcentagem) e o índice Kappa (apresentado em proporção). O índice

Tabela 4. Matrizes de confusão das cinco técnicas aplicadas nas imagens Landsat 5 TM com resolução espacial de 30 metros.

Table 4. Confusion matrices of the five processing techniques applied in *Landsat* 5 TM imagery with 30 meters spatial resolution.

Normalized Difference Vegetation Index (NDVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	176	157	333	98,88%	52,85%	47,15%	1,12%	53,64%	0,04
A. explorada	2	8	10	4,85%	80,00%	20,00%	95,15%		
Total	178	165	343	--	--	--	--		
Global Environmental Monitoring Index (GEMI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	178	164	342	100,00%	52,05%	47,95%	0,00%	52,19%	0,01
A. explorada	0	1	1	0,61%	100,00%	0,00%	100,00%		
Total	178	165	343	--	--	--	--		
Modified Soil Adjusted Vegetation Index (MSAVI)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	176	157	333	98,88%	52,85%	47,15%	1,12%	53,64%	0,04
A. explorada	2	8	10	4,85%	80,00%	20,00%	95,15%		
Total	178	165	343	--	--	--	--		
Análise de componentes principais (ACP)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	173	140	313	97,19%	55,27%	44,73%	2,81%	57,73%	0,13
A. explorada	5	25	30	15,15%	83,33%	16,67%	84,85%		
Total	178	165	343	--	--	--	--		
Modelo linear de mistura espectral (MLME)									
Classificação	Dado de referência			Acurácia do produtor	Acurácia do usuário	Erro de comissão	Erro de omissão	Acurácia global	Índice Kappa
	Floresta	A. explorada	Total						
Floresta	177	154	331	99,44%	53,47%	46,53%	0,56%	54,81%	0,06
A. explorada	1	11	12	6,67%	91,67%	8,33%	93,33%		
Total	178	165	343	--	--	--	--		

Kappa compara os resultados obtidos a uma classificação aleatória, considerando a classificação de forma global e não fazendo uma média entre as acurácias das classes consideradas, como acontece no cálculo da acurácia global.

A grande quantidade de pixels atribuídos à classe de interesse nas classificações geradas a partir dos índices de vegetação, inclusive nas áreas não exploradas na UPA, sugere que o grau de mudança ocasionado pela exploração florestal é similar às mudanças naturais que ocorrem na floresta de um ano para o outro. Esse resultado corrobora a afirmação defendida por D'Oliveira et al. (2012) de que grande parte das alterações ocasionadas

pela exploração florestal de impacto reduzido está dentro da variabilidade natural encontrada em áreas de floresta primária, quando o dossel é visto de cima pelos sensores ópticos (no nível do solo as mudanças são muito mais evidentes).

4. CONCLUSÕES E CONSIDERAÇÕES FINAIS

A acurácia global máxima obtida na detecção da infraestrutura florestal obtida nesta análise foi de aproximadamente 70%, com a utilização do índice de vegetação NDVI na resolução espacial de 5 metros.

Valores de acurácia menores ainda foram obtidos para a classe de interesse (área explorada). As imagens ópticas são normalmente utilizadas no monitoramento do corte seletivo em florestas tropicais, possibilitando a detecção de sua ocorrência baseada em uma série de elementos de contexto que constituem seu padrão espacial, mas são limitadas em sua capacidade de distinguir as mudanças estruturais que ocorrem abaixo do dossel (Coops et al., 2007), como é o caso de grande parte das alterações que ocorrem devido à execução do manejo florestal.

O GEMI apresentou o pior desempenho dentre as técnicas utilizadas nas três resoluções espaciais consideradas. Esse índice foi concebido para uso em monitoramento global e essa pode ser uma razão pela qual o teste em pequenas áreas como as UPA da Flona do Jamari não obteve bons resultados. Ele também já foi aplicado em imagens de média resolução espacial em escala regional (Matricardi et al., 2010; Wang et al., 2005), mas em nenhum desses trabalhos foi indicado como melhor opção em relação aos outros índices e/ou técnicas utilizados.

Numa área com exploração florestal de impacto reduzido como é o caso das concessões florestais é fundamental o uso de imagens ópticas com maior resolução espacial ou de sensores ativos, especialmente se o objetivo é avaliar e monitorar impactos que ocorrem em pequena escala (remoção de uma árvore, abertura de ramais de arraste). Os resultados encontrados com as imagens Landsat neste estudo apontam claramente essa necessidade. O uso de dados de aerolevanteamento com tecnologia *de perfilhamento a laser* (LiDAR) tem mostrado grande potencial e resultados promissores para esse fim (Andersen et al., 2014; Kent et al., 2015).

STATUS DA SUBMISSÃO

Recebido: 21 out., 2013

Aceito: 30 mar., 2015

AUTOR(ES) PARA CORRESPONDÊNCIA

Ekena Rangel Pinagé

Embrapa Monitoramento por Satélite,
CEP 13070-115, Campinas, SP, Brasil
e-mail: ekenapinage@hotmail.com

REFERÊNCIAS

- Andersen HE, Reutebuch SE, McGaughey RJ, d'Oliveira MVN, Keller M. *Monitoring selective logging in western Amazonia with repeat lidar flights. Remote Sensing of Environment* 2014; 151: 157-165. <http://dx.doi.org/10.1016/j.rse.2013.08.049>.
- Asner GP, Knapp DE, Broadbent EN, Oliveira PJC, Keller M, Silva JN. *Selective logging in the Brazilian Amazon. Science* 2005; 310(5747): 480-482. <http://dx.doi.org/10.1126/science.1118051>. PMID:16239474.
- Congalton RG, Green K. *Assessing the accuracy of remotely sensed data*. 2. ed. Boca Raton: CRC Press; 2008. <http://dx.doi.org/10.1201/9781420055139>.
- Coops NC, Hilker T, Wulder MA, St-Onge B, Newnham G, Siggins A et al. *Estimating canopy structure of Douglas-fir forest stands from discrete-return LIDAR. Trees - Structure and Function* 2007; 21(3): 295-310. <http://dx.doi.org/10.1007/s00468-006-0119-6>.
- D'Oliveira MVN, Reutebuch SE, McGaughey RJ, Andersen HE. *Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. Remote Sensing of Environment* 2012; 124: 479-491. <http://dx.doi.org/10.1016/j.rse.2012.05.014>.
- Instituto Brasileiro de Geografia e Estatística - IBGE. *Manual técnico da vegetação brasileira*. 2. ed. Rio de Janeiro: IBGE; 2012.
- Instituto Floresta Tropical - IFT. [online]. [citado em 2011 set. 9]. Disponível em: <http://www.ift.org.br/>
- Instituto Nacional de Pesquisas Espaciais - INPE. *Metodologia para o cálculo da taxa anual de desmatamento na Amazônia Legal* [online]. São José dos Campos: INPE; 2006. [citado em 2011 jul. 21]. Disponível em: <http://www.obt.inpe.br/prodes/metodologia.pdf>
- Kent R, Lindsell JA, Laurin GV, Valentini R, Coomes DA. *Airborne LiDAR detects selectively logged tropical forest even in an advanced stage of recovery. Remote Sensing* 2015; 7: 8348-8367. <http://dx.doi.org/10.3390/rs70708348>.
- Lillesand TM, Kiefer RW, Chipman JW. *Remote sensing and image interpretation*. 6. ed. Hoboken: John Wiley & Sons; 2008.
- Matricardi EAT, Skole DL, Pedlowski MA, Chomentowski W, Fernandes LC. *Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. Remote Sensing of Environment* 2010; 114(5): 1117-1129. <http://dx.doi.org/10.1016/j.rse.2010.01.001>.
- Meneses PR, Almeida T. Transformação por rotação espectral. In: Meneses PR, Almeida T, editores. *Introdução ao processamento de imagens de sensoriamento remoto*. Brasília: UnB:CNPq; 2012.

- Pinty B, Verstraete MM. *GEMI: a non-linear index to monitor global vegetation from satellites*. *Vegetatio* 1992; 101(1): 15-20. <http://dx.doi.org/10.1007/BF00031911>.
- Ponzoni FJ, Shimabukuro YE. *Sensoriamento remoto no estudo da vegetação*. 2. ed. São José dos Campos: Parêntese; 2009.
- Qi J, Chehbouni A, Huete AR, Kerr YH, Sorooshian S. *A modified soil adjusted vegetation index*. *Remote Sensing of Environment* 1994; 48(2): 119-126. [http://dx.doi.org/10.1016/0034-4257\(94\)90134-1](http://dx.doi.org/10.1016/0034-4257(94)90134-1).
- Rouse JW, Haas RH, Schell JA, Deering DW. *Monitoring vegetation systems in the great plains with ERTS*. In: *Third ERTS Symposium Abstracts*; 1973; Washington. Greenbelt, MD: NASA; 1973. p. 309-317.
- Shimabukuro YE, Smith JA. *The least-squares mixing models to generate fraction images derived from remote sensing multispectral data*. *International Journal of Remote Sensing* 1991; 29: 16-20.
- Silva FB, Fonseca LMG, Valeriano DM, Shimabukuro YE. *Identificação de processos de desmatamento seletivo na região amazônica utilizando dados orbitais e técnicas de processamento digital de imagens*. In: *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*; 2009; Natal. São José dos Campos: INPE; 2009. p. 3043-3049.
- Souza C Jr, Roberts D, Cochrane MA. *Combining spectral and spatial information to map canopy damage from selective logging and forest fires*. *Remote Sensing of Environment* 2005; 98(2-3): 329-343. <http://dx.doi.org/10.1016/j.rse.2005.07.013>.
- Uhl C, Vieira ICG. *Ecological impacts of selective logging in the Brazilian Amazon - a case study from the Paragominas Region of the State of Pará*. *Biotropica* 1989; 21(2): 98-106. <http://dx.doi.org/10.2307/2388700>.
- Wang C, Qi J, Cochrane M. *Assessment of Tropical Forest degradation with canopy fractional cover from landsat ETM+ and IKONOS imagery*. *Earth Interactions* 2005; 9(22): 1-18. <http://dx.doi.org/10.1175/EI133.1>.