



**NATHÁLIA SILVA DE CARVALHO**

**SÉRIES TEMPORAIS TM/RAPIDEYE PARA A  
DETECÇÃO DE PEQUENOS DISTÚRBIOS EM  
FLORESTAS TROPICAIS**

**LAVRAS – MG**

**2016**

**NATHÁLIA SILVA DE CARVALHO**

**SÉRIES TEMPORAIS TM/RAPIDEYE PARA A DETECÇÃO DE  
PEQUENOS DISTÚRBIOS EM FLORESTAS TROPICAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

Orientador

Dr. Luis Marcelo Tavares de Carvalho

**LAVRAS - MG**

**2016**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha  
Catalográfica da Biblioteca Universitária da UFLA, com dados  
informados pelo(a) próprio(a) autor(a).**

Carvalho, Nathália Silva de.

Séries temporais TM/RapidEye para a detecção de pequenos  
distúrbios em florestas tropicais / Nathália Silva de Carvalho. – Lavras:  
UFLA, 2016.

115 p.

Dissertação (mestrado acadêmico) – Universidade Federal de Lavras,  
2016.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Desmatamento. 2. BFAST Monitor. 3. Tempo computacional. 4.  
Multi-sensor. 5. Gestão ambiental. I. Universidade Federal de Lavras. II.  
Título.

**NATHÁLIA SILVA DE CARVALHO**

**SÉRIES TEMPORAIS TM/RAPIDEYE PARA A  
DETECÇÃO DE PEQUENOS DISTÚRBIOS EM FLORESTAS  
TROPICAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

APROVADA em 20 de maio de 2016.

Dr. Elpídio Inácio Fernandes Filho UFV

Dra. Margarete Marin Lordelo Volpato EPAMIG

Dr. Luis Marcelo Tavares de Carvalho  
Orientador

**LAVRAS – MG  
2016**

*Existem muitas hipóteses na ciência que são erradas. Isso é perfeitamente correto; elas são a abertura para descobrir o que é certo. A ciência é um processo autocorretivo. Para serem aceitas, novas ideias devem sobreviver aos mais rigorosos padrões de evidência e escrutínio.*

Carl Sagan

*A Deus.  
À minha família.  
Aos verdadeiros  
amigos.*

## AGRADECIMENTOS

Agradeço a Deus por guiar minhas escolhas, permitindo que mais essa meta fosse alcançada. Agradeço por me permitir compartilhar as experiências desta vida com tantas pessoas incríveis, que me fortaleceram ao longo deste caminho.

À Universidade Federal de Lavras, em especial ao Programa de Pós-Graduação em Engenharia Florestal e ao Laboratório de Estudos e Projetos em Manejo Florestal (LEMAF). Toda a infraestrutura disponível nos laboratórios foi essencial para o desenvolvimento desta dissertação.

Ao meu orientador, professor Dr. Luis Marcelo (Passarinho), pela amizade, por todo o aprendizado na área de sensoriamento remoto e por suas contribuições para o desenvolvimento deste trabalho. O apoio nesta dissertação foi fundamental para expandir o meu conhecimento científico e criar novas perspectivas acadêmicas.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela concessão da bolsa de estudos.

Aos membros da banca, por todas as contribuições para o enriquecimento deste trabalho.

Também gostaria de agradecer a algumas pessoas pelo apoio técnico. À equipe da BlackBridge e da Santiago & Cintra, pela disponibilização das imagens RapidEye. Em especial, ao Maurício Meira, por sua disponibilidade, auxiliando na aquisição do banco de imagens. À Maria Marta Guevara e Adrian Gonzalez, pelo processamento dos dados e a Mauricio Schiavolin e André Freire, por auxiliarem neste processo.

Aos pesquisadores Loïc Dutrieux e Ben DeVries. O progresso ao longo de tantas tentativas e erros só foi possível por causa da colaboração destes

pesquisadores esclarecendo minhas dúvidas, o que me auxiliou na compreensão e na análise de séries temporais no BFAST Spatial.

Ao Liliano, por ser sempre prestativo, instalando *softwares* e recuperando arquivos.

Agradeço, em especial, ao Lab 46, por compartilhar todas as experiências, frustrações e alegrias ao conseguir um processamento correto no R! Em especial à Carol, Lisi e Tássia, pela amizade e por todas as palavras de incentivo. Ao Daniel, pelas conversas que me ajudaram no desenvolvimento deste trabalho e à Paulinha, estagiária dedicada!

Às Panamenhas e a toda equipe P.F.C.! A companhia de vocês, todas as quartas-feiras, foi essencial para diminuir a tensão ao longo deste trabalho.

Às amigas que conquistei no LEMAF: Poly, Thaís e Mônica, e às amigas que conquistei na Ecologia: Nay, Paula, André, Perdido, Mardy, Tonho, Ananza, Wallace, Fabrício e Ernesto. A presença de todos vocês tornou este percurso mais leve, me proporcionando muitas histórias boas para lembrar!

Às minhas eternas amigas de toda uma vida, Karen e Rafa, que sempre estiveram presentes e me deram forças para concluir mais esta etapa.

Finalmente, agradeço à minha família, a melhor parte de mim. Meus pais, Vera e Sérgio, que me apoiaram incondicionalmente nas minhas escolhas; minha irmã, Priscila; minha sobrinha, Beatriz, fonte de tantos sorrisos e à minha avó Maria, a quem devo tantos ensinamentos.

Enfim, gostaria de agradecer a todas as pessoas que contribuíram, direta ou indiretamente, para o desenvolvimento desta dissertação. O apoio acadêmico e/ou pessoal de cada um tornou o desenvolvimento deste projeto de pesquisa mais agradável, contribuindo para o meu crescimento profissional ao longo deste percurso. Sou muito grata a todos vocês!

## RESUMO

Esta dissertação foi desenvolvida fundamentando-se na necessidade de novas metodologias para auxiliar na fiscalização dos remanescentes de vegetação nativa, principalmente para áreas com um alto nível de fragmentação florestal. Além disso, os ecossistemas tropicais são fundamentais para a manutenção dos serviços ecológicos, além de abrigarem a maior biodiversidade mundial. Entretanto, o desmatamento corresponde a uma das principais atividades antrópicas que têm afetado a estabilidade desses ambientes. Dessa maneira, o monitoramento da dinâmica das florestas tropicais é fundamental para a tomada de decisão para a gestão pública e ambiental desses ecossistemas. Neste contexto, esta dissertação foi estruturada em dois capítulos, dos quais no primeiro aborda-se toda a problemática para o monitoramento de desmatamentos de pequena escala em ecossistemas tropicais, que têm grande interferência antrópica. Já o segundo capítulo inclui a aplicação de uma nova metodologia para a detecção de pequenos desmatamentos, considerando as lacunas do conhecimento para o monitoramento da vegetação em ecossistemas tropicais. Diante disso, o objetivo geral, neste trabalho, foi propor uma nova metodologia utilizando séries temporais multissensor (TM/RapidEye) baseadas em objeto, para reduzir o tempo computacional e melhorar a precisão da detecção automática de pequenos desmatamentos, aplicando o algoritmo BFAST Monitor. O estudo foi desenvolvido em uma área de Mata Atlântica, localizada em Santa Catarina, no sul do Brasil. Neste bioma, o processo de desmatamento é caracterizado por pequenos eventos pontuais dispersos em uma matriz antrópica. Para a construção das séries temporais, foram adquiridas 230 imagens TM (órbita/ponto 227/068), entre 1984 e 2011 e 20 imagens RapidEye (tile 2226122), entre 2009 e 2011. Foram construídas oito séries temporais com imagens-objeto, sendo o valor de cada pixel correspondente ao valor do parâmetro estatístico extraído de cada objeto (média ou mínimo), em cada imagem da série temporal. Na análise pelo BFAST Monitor, é necessária a definição de um período histórico e um período de monitoramento. Em seguida, um modelo de regressão é ajustado para o conjunto de dados identificado como período histórico estável. A identificação deste período é fundamental para distinguir as mudanças entre naturais e abruptas (mudanças de interesse). Posteriormente, a estabilidade deste modelo é testada para o conjunto de dados do período de monitoramento. Se a hipótese de estabilidade estrutural for rejeitada, um *breakpoint* (possível mudança) será detectado. Neste trabalho, o período histórico foi configurado entre 1984 e 2010 e o período de monitoramento como o ano de 2011. Os resultados obtidos elucidaram um grande potencial da metodologia aplicada, uma vez que o uso de imagens-objeto reduziu o tempo de processamento em 95% e a inserção de imagens RapidEye para a construção de séries temporais multissensor determinou um aumento de

quatro vezes na capacidade de detecção automática dos pequenos desmatamentos identificados na região avaliada.

Palavras-chave: Desmatamento. BFAST Monitor. Tempo computacional. Análise Temporal. Gestão Ambiental.

## ABSTRACT

This dissertation was developed based on the need for new methodologies to assist in the inspection of remaining native vegetation, especially for areas with a high level of forest fragmentation. Furthermore, considering the tropical ecosystems, they are essential for the maintenance of ecological services, and shelter the world's largest biodiversity. However, deforestation represents one of the principal human activities that have affected the stability of these environments. Thus, monitoring the dynamics of tropical forests is critical for decision-making for public and environmental management of these ecosystems. Given this context, this work was structured in two chapters, in which the first chapter covers all problematic for monitoring of small-scale deforestation in tropical ecosystems, which have a great anthropic interference. The second chapter includes the application of a new methodology for the detection of small deforestations, considering the knowledge gaps for monitoring the vegetation in tropical ecosystems. Thus, the aim of this study was to propose a new methodology using object-based multi-sensor time series (TM/RapidEye), to reduce the computational time and improve the accuracy of automatic detection of small deforestations, applying the BFAST Monitor algorithm. The study was developed in an Atlantic Forest area, located in Santa Catarina, in southern Brazil. In this biome, the deforestation process is characterized by small punctual events dispersed in an anthropic matrix. For the construction of the time series, 230 TM images were acquired (path/row 227/068), between 1984 and 2011, and 20 RapidEye images (tile 2226122) from 2009 to 2011. Eight time series were built with object-images, the value of each pixel corresponding to the value of the statistical parameter extracted from each object (average or minimum) in each image of the time series. In the analysis by BFAST Monitor it is necessary to define a historical period and a monitoring period. A regression model is then fit to the data set identified as the stable historical period. The identification of this period is critical for distinguishing between natural and abrupt changes (changes of interest). Subsequently, stability in this model is tested for the monitoring period data set. If the structural stability hypothesis is rejected, a breakpoint (potential change) is detected. In this work, the historical period was set between 1984 and 2010 and the monitoring period as the year 2011. The results elucidated great potential on the methodology, since the use of object-images reduced processing time by 95%, and inserting RapidEye images for building multi-sensor time series, provided a fourfold increase in the automatic detection capability of small deforestations identified in the assessed region.

Keywords: Deforestation. BFAST Monitor. Computer Time. Temporal Analysis. Environmental Management.

## LISTA DE FIGURAS

- Figura 1 - Construção de uma série temporal a partir de imagens de satélite, na qual o comportamento de cada pixel é avaliado ao longo do tempo. Adaptado de Maus (2014).....38
- Figura 2 - Análise a partir do pacote bfastSpatial disponível para o software R. Resultado do BFAST Monitor para a trajetória temporal de um pixel no qual um breakpoint foi detectado. ....42
- Figura 3 - Localização da área de estudo, na região sul do estado de Santa Catarina. Em detalhe, o subset da área avaliada para a imagem RapidEye de 22/09/2011, na composição RGB 5-3-2. ....63
- Figura 4 - Representação esquemática da metodologia para construção das imagens baseadas em objeto. O código-fonte foi escrito na linguagem IDL.....68
- Figura 5 - Fluxograma das três etapas de análise do BFAST Monitor para a detecção de desmatamentos nas séries temporais com imagens-objeto.....71
- Figura 6 - Fluxograma da metodologia para construção das séries temporais baseadas em objeto e utilizadas para análise no BFAST Monitor. .77
- Figura 7 - Fluxograma para a construção das quatro séries temporais com imagens-objeto, utilizando o período histórico TM. ....78
- Figura 8 - Fluxograma para construção das quatro séries temporais com imagens-objeto, utilizando o período histórico multissensor TMRE. ....79
- Figura 9 - Perfil temporal de três objetos da série TMRE/RE\_mean, para diferentes valores de magnitude. ....86
- Figura 10 - Valor percentual dos parâmetros extraídos a partir da matriz de confusão para os breakpoints detectados considerando os limites de magnitude. ....88
- Figura 11 - Comparação entre dois perfis temporais para um mesmo objeto de desmatamento, a partir dos valores médios de NDVI. Ambas as séries temporais têm um período histórico constituído somente por imagens TM. No gráfico A está representada a série temporal TM/TM\_mean e, no gráfico B, a série temporal TM/RE\_mean.....92
- Figura 12 - Comparação entre dois perfis temporais para um mesmo objeto de desmatamento, a partir dos valores médios de NDVI. Ambas as séries temporais têm um período histórico multissensor, constituído por imagens TM e RapidEye. No gráfico A, está representada a série temporal TMRE/TM\_mean e, no gráfico B, a série temporal TMRE/RE\_mean.....92

Figura 13 - Erro de comissão para as oito séries temporais, considerando os breakpoints com uma magnitude $<-0,0001$ . Em vermelho estão representados os objetos de desmatamento que foram detectados corretamente pelo BFAST Monitor, enquanto os objetos na cor preta representam aqueles detectados incorretamente. A área em cinza consiste na região de vegetação que não foi alterada no período avaliado e as áreas em branco incluem as áreas mascaradas nas análises. ....	95
Figura 14 - Erro de omissão para as oito séries temporais, considerando os breakpoints com magnitude $<-0,0001$ . Em vermelho estão representados os objetos de desmatamento que foram detectados corretamente pelo BFAST Monitor, enquanto os objetos na cor preta foram omitidos. A área em cinza consiste na região de vegetação que não foi alterada no período avaliado e as áreas em branco incluem as áreas mascaradas nas análises. ....	97
Figura 15 - Número de objetos de desmatamento/classe de magnitude, identificados pelo intérprete e detectados pelo BFAST Monitor....	98
Figura 16 - Trajetória temporal de um objeto de desmatamento que não foi detectado pelo BFAST Monitor.....	100
Figura 17 - Exemplo da influência sazonal objeto de floresta plantada. Imagens RapidEye do ano de 2011, em uma composição RGB 5-3-2. ....	102

## LISTA DE TABELAS

Tabela 1 - Distribuição das imagens ao longo da série temporal TM de 28 anos (1984-2011). .....	65
Tabela 2 - Parâmetros configurados para a análise das séries temporais pelo BFAST Monitor, em que OB = object-based; ROC = Reversed Ordered Cumulative; MOSUM = Soma Móvel. ....	71
Tabela 3 - Número de imagens TM e RapidEye utilizadas no período histórico e no período de monitoramento, para construção das oito séries temporais baseadas em objeto. ....	78
Tabela 4 - Valor percentual para as acurácias do produtor e do usuário, assim como para os erros de omissão e comissão, considerando os breakpoints com magnitude $<-0,0001$ , detectados nas oito séries temporais baseadas em objetos. ....	90
Tabela 5 - Relação dos 75 objetos de desmatamento detectados pelo intérprete, classificados de acordo com seu valor de magnitude. ..	100

## LISTA DE SIGLAS

ALOS	Advanced Land Observing Satellite
ATCOR	Atmospheric and Topographic Correction
BFAST	Breaks For Additive Seasonal and Trend
CAR	Cadastro Ambiental Rural
CCDC	Continuous Change Detection and Classification
CDR	Surface Reflectance Climate Data Record
CMFDA	Continuous Monitoring of Forest Disturbance Algorithm
DMC	Disaster Monitoring Constellation
DOS	Dark Object Subtraction
EOS	Earth Observing System
ETM	Enhanced Thematic Mapper
ETM <sup>+</sup>	Enhanced Thematic Mapper Plus
IBGE	Instituto Brasileiro de Geografia e Estatística
LandTrendr	Landsat-based detection of Trends in Disturbance and Recovery
LEDAPS	Landsat Ecosystem Disturbance Adaptive Processing System
MMA	Ministério do Meio Ambiente
MODIS	Moderate Resolution Imaging Spectro-radiometer
MOSUM	Soma móvel
MRT	MODIS Re-projection Tools
NASA	National Aerospace and Space Administration
NBR	Normalized Burn Ratio
NDVI	Normalized Difference Vegetation Index
NIR	Banda do infravermelho próximo
OB	Object-Based
QUAC	Quick Atmospheric Correction
RED	Banda do vermelho

ROC	Reversed Ordered Cumulative
STARS	Spectral–Temporal Analysis by Response Surface
TM	Thematic Mapper
TREES	Tropical Ecosystem Environment Observation by Satellite
VCT	Vegetation Change Tracker
USGS	United States Geological Survey
UTM	Universal Transversa de Mercator
6S	Second Simulation of the Satellite Signal in the Solar Spectrum

## SUMÁRIO

	<b>CAPÍTULO 1</b> .....	18
<b>1</b>	<b>INTRODUÇÃO GERAL</b> .....	18
<b>2</b>	<b>OBJETIVOS</b> .....	21
<b>3</b>	<b>ESTRUTURA DA DISSERTAÇÃO</b> .....	22
<b>4</b>	<b>REFERENCIAL TEÓRICO</b> .....	24
<b>4.1</b>	<b>Sensores remotos</b> .....	24
<b>4.2</b>	<b>NDVI</b> .....	27
<b>4.3</b>	<b>Pré-processamento: influência de fatores externos na resposta espectral</b> .....	28
<b>4.4</b>	<b>Deteção de mudança baseada em objeto</b> .....	30
<b>4.5</b>	<b>Abordagem multissensor para detecção de mudança</b> .....	33
<b>4.6</b>	<b>Matriz de confusão</b> .....	35
<b>4.7</b>	<b>Séries temporais para detecção de mudanças na vegetação</b> .....	36
<b>4.8</b>	<b>BFAST Monitor</b> .....	41
	<b>REFERÊNCIAS</b> .....	45
	<b>CAPÍTULO 2 Uso de séries temporais TM/RapidEye para a deteção de desmatamentos na Mata Atlântica</b> .....	54
<b>1</b>	<b>INTRODUÇÃO</b> .....	58
<b>2</b>	<b>MATERIAL E MÉTODOS</b> .....	62
<b>2.1</b>	<b>Área de estudo</b> .....	62
<b>2.2</b>	<b>Aquisição e pré-processamento das imagens TM e <i>RapidEye</i></b> .....	64
<b>2.3</b>	<b>Máscara de vegetação aplicada a 2011</b> .....	66
<b>2.4</b>	<b>Séries temporais baseadas em objeto</b> .....	66
<b>2.4.1</b>	<b>Construção das imagens-objeto</b> .....	66
<b>2.4.2</b>	<b>Construção das séries temporais com imagens-objeto TM e <i>RapidEye</i></b> .....	68
<b>2.5</b>	<b>BFAST Monitor</b> .....	70
<b>2.5.1</b>	<b>Ajuste do modelo de tendência e sazonalidade</b> .....	72
<b>2.5.2</b>	<b>Deteção de breakpoints no período de monitoramento</b> .....	73
<b>2.5.3</b>	<b>Intervalo da magnitude para o período de monitoramento</b> .....	74
<b>2.5.4</b>	<b>Deteção de desmatamento com séries temporais multissensor baseadas em objeto</b> .....	75
<b>2.6</b>	<b>Validação dos resultados</b> .....	79
<b>2.6.1</b>	<b>Tempo computacional: pixel x OB</b> .....	79
<b>2.6.2</b>	<b>Elaboração do mapa de referência para 2011</b> .....	80
<b>3</b>	<b>RESULTADOS &amp; DISCUSSÃO</b> .....	82
<b>3.1</b>	<b>Séries temporais multissensor TM/RapidEye baseadas em objeto</b> ..	82
<b>3.2</b>	<b>Caracterização da dinâmica florestal na área de estudo</b> .....	85
<b>3.3</b>	<b>Relação entre os limites de magnitude e as matrizes de confusão</b> ....	86

3.4	Influência das imagens RapidEye na detecção dos desmatamentos	89
3.5	Principais fontes de erros na detecção de <i>breakpoints</i>	94
3.5.1	Parâmetros estatísticos e o erro de comissão	94
3.5.2	Magnitude e o erro de omissão	96
3.6	Limitações e pesquisas futuras	101
4	CONSIDERAÇÕES FINAIS	104
5	CONCLUSÃO	106
	REFERÊNCIAS	108
	APÊNDICES	114

## CAPÍTULO 1

### 1 INTRODUÇÃO GERAL

Os ecossistemas tropicais são fundamentais para a estabilidade de ciclos biológicos, a regulação climática e o sequestro de carbono, além de constituírem as regiões com a maior biodiversidade e abrigarem a maior parte dos *hotspots* do mundo (MYERS et al., 2000). Entretanto, as alterações na cobertura da terra destes ambientes estão entre os principais agentes causadores das mudanças ambientais globais (FOLEY et al., 2005).

Nesta perspectiva, para combater o desmatamento da vegetação nativa no Brasil, em 2012 foi criado o Cadastro Ambiental Rural (CAR), um registro eletrônico de todos os imóveis rurais, com a finalidade de auxiliar no planejamento ambiental e econômico dessas propriedades. Como suporte ao programa, o Ministério do Meio Ambiente adquiriu a cobertura completa de imagens *RapidEye* para todo o território nacional, a fim de mapear e monitorar a dinâmica dos remanescentes de vegetação nativa de todo o país.

Este banco de dados constituído por imagens de alta resolução espacial será fundamental para aprimorar o monitoramento de biomas com grande interferência antrópica, como, por exemplo, a Mata Atlântica. O processo de desmatamento neste bioma é distinto do cenário observado para regiões como a Floresta Amazônica, na qual a remoção da cobertura florestal é resultante de recentes incentivos governamentais para a expansão da fronteira agrícola (FEARNSIDE, 2008). Neste bioma, o desmatamento é caracterizado por processos como “espinha-de-peixe” (RUDEL et al., 2009) ou pela remoção de grandes áreas florestais para a criação de gado extensiva (OLIVEIRA-FILHO; METZGER, 2006). Ambos os padrões são visualmente identificáveis na paisagem. Já o desmatamento na Mata Atlântica é decorrente de atividades

antrópicas ao longo dos últimos cinco séculos (TEIXEIRA et al., 2009). Este processo culminou em remanescentes de vegetação nativa representados, em sua maioria, por pequenos fragmentos florestais (RIBEIRO et al., 2009). Dessa maneira, observa-se um padrão inverso, no qual o desmatamento é caracterizado por pequenos eventos pontuais dispersos em uma matriz antrópica, o que dificulta o monitoramento da vegetação neste bioma.

Portanto, a fim de melhorar a detecção de mudanças na vegetação nestas áreas, três fatores motivaram o desenvolvimento deste trabalho: (i) a disponibilidade de imagens RapidEye, a qual pode auxiliar na detecção de pequenos desmatamentos; (ii) a política de acesso livre ao arquivo Landsat (WOODCOCK et al., 2008), o qual possibilita obter um comportamento histórico da vegetação ao longo dos últimos 30 anos e (iii) a necessidade de desenvolver metodologias para monitorar desmatamentos de pequena escala.

Este conjunto de fatores condicionou a escolha do domínio temporal como alvo de análise para a detecção de mudanças. Esta abordagem é apropriada para regiões tropicais, uma vez que, para análises bitemporais, a aquisição de imagens em datas aniversariantes é dificultada pela alta frequência de nuvens nestas regiões (LU et al., 2004). Além disso, os resultados correspondem a uma resposta estática (mudança ou não mudança), não sendo possível identificar quando e como o processo ocorreu ao longo do tempo (ZHU; WOODCOCK; OLOFSSON, 2012).

Contudo, as aplicações das metodologias que utilizam a trajetória multitemporal para a detecção de mudanças têm sido direcionadas para regiões que têm um padrão de desmatamento distinto do observado na Mata Atlântica (HUANG et al., 2010; KENNEDY; YANG; COHEN, 2010; ZHU; WOODCOCK; OLOFSSON, 2012). Dessa maneira, este trabalho justifica-se pela necessidade de aprimorar as metodologias para a fiscalização dos remanescentes de vegetação nativa, principalmente em áreas com um alto nível

de fragmentação florestal. Portanto, nessa dissertação foi avaliada como a combinação de imagens de média (TM) e alta resolução espacial (RapidEye) em séries temporais podem auxiliar no monitoramento destas áreas. Para a análise deste conjunto de dados, foi utilizado o algoritmo BFAST Monitor, uma vez que, em estudos recentes, evidenciou-se a sua aplicação para a detecção de distúrbios na vegetação em ecossistemas tropicais (DEVRIES et al., 2015; DUTRIEUX et al., 2015; STEPHAN, 2015).

A nova abordagem proposta neste trabalho poderá contribuir com novas ferramentas para o monitoramento, a longo prazo, dos remanescentes de vegetação nativa de todo o território nacional, o qual corresponde a um desafio metodológico devido à sua dimensão continental, associada à grande heterogeneidade dos seus biomas. Nesta perspectiva, a metodologia abordada poderá subsidiar projetos de monitoramento, como, por exemplo, o Cadastro Ambiental Rural, no qual é fundamental uma metodologia que priorize a redução do tempo computacional.

## 2 OBJETIVOS

Diante da disponibilidade do banco de dados com imagens de média (Landsat/TM) e alta resolução espacial (RapidEye), o objetivo geral, nesta dissertação, foi propor uma nova metodologia utilizando séries temporais multissensor baseadas em objeto para reduzir o tempo computacional e melhorar a precisão da detecção automática de pequenos desmatamentos, aplicando o algoritmo BFAST Monitor. Os objetivos específicos consistiram em:

- a) comparar o tempo computacional despendido para o processamento de séries temporais em nível de pixel em relação a séries temporais com imagens baseadas em objeto, aplicando o BFAST Monitor;
- b) comparar a acurácia dos desmatamentos detectados pelo BFAST Monitor a partir das séries temporais baseadas em objeto construídas apenas com imagens TM, assim como com imagens TM e RapidEye.

### 3 ESTRUTURA DA DISSERTAÇÃO

No intuito de investigar o uso de séries temporais para a detecção de mudanças na vegetação, a dissertação foi organizada em dois capítulos, com os seguintes conteúdos:

- a) **Capítulo 1 – Introdução Geral:** este capítulo inicia-se com uma introdução geral abordando a problemática para o monitoramento de desmatamentos de pequena escala em ecossistemas tropicais, com grande interferência antrópica. Neste tópico também são descritos os fatores que motivaram o desenvolvimento deste trabalho, assim como as contribuições provenientes desta pesquisa para aprimorar a análise de séries temporais. Em seguida, no referencial teórico são elucidados os conceitos fundamentais para análises de detecção de mudanças na cobertura da terra. Posteriormente, são evidenciadas as contribuições da metodologia baseada em objeto e da abordagem multissensor, para as análises de detecção de mudança. Para finalizar, este capítulo também inclui uma revisão dos principais métodos descritos na literatura para a detecção de mudanças na vegetação, utilizando séries temporais.
- b) **Capítulo 2 - Uso de séries temporais TM/RapidEye para a detecção de desmatamentos na Mata Atlântica:** este capítulo pode ser resumido em três fatores correspondentes a lacunas do conhecimento para o monitoramento da vegetação em ecossistemas tropicais: (i) literatura escassa, aplicando algoritmos de séries temporais para o monitoramento destes ecossistemas; (ii) ausência de metodologias para reduzir o tempo de processamento destes banco de dados e (iii) uso restrito de imagens multissensor na construção de séries temporais. A partir disso, neste capítulo é

descrita a metodologia para a construção das séries temporais baseadas em objeto, com imagens TM e RapidEye. Posteriormente, os resultados são baseados na análise da acurácia dos desmatamentos detectados pelo BFAST Monitor.

## **4 REFERENCIAL TEÓRICO**

### **4.1 Sensores remotos**

Os sensores remotos correspondem a instrumentos sensíveis à radiação eletromagnética, os quais são capazes de identificar e distinguir os diferentes alvos da superfície terrestre, devido às diferenças no comportamento espectral. Dessa maneira, o monitoramento das alterações das feições na superfície terrestre por meio de imagens de satélite é viável devido à elevada taxa de repetição na aquisição de registros, além de representar a melhor ferramenta considerando a relação custo-benefício para o monitoramento de áreas extensas (JENSEN, 2006). Estas vantagens estão associadas ao fato de que sensores remotos consistem em dispositivos capazes de obter informações sem que exista um contato físico com o alvo de interesse.

A aplicação das informações adquiridas de diferentes sensores depende, principalmente, de quatro tipos de resoluções: (i) resolução espacial, a qual representa a menor unidade de imageamento e está relacionada ao IFOV (campo de visada instantâneo), que depende da abertura da lente e altura do sensor; (ii) resolução radiométrica, a qual corresponde ao potencial para distinguir os diferentes níveis de cinza de acordo com o menor intervalo de energia radiante que pode ser detectada pelo sensor; (iii) resolução espectral, à qual é representada pelo número de bandas do sistema sensor, largura e posição em que estão situadas no espectro eletromagnético e (iv) resolução temporal, correspondente à frequência de revisita do sistema satélite à mesma área (JENSEN, 2006).

A disponibilização de imagens de alta resolução espacial tem permitido uma identificação mais detalhada das entidades geográficas, fornecendo informações que têm aprimorado estudos de monitoramento da dinâmica na

cobertura da terra (BOVOLO et al., 2012; WULDER et al., 2004). Neste caso, destacam-se as imagens RapidEye obtidas a partir de uma constelação de cinco satélites idênticos, lançados em 29 de agosto de 2008. De acordo com as especificações do produto adquirido, as imagens podem apresentar resolução espacial de 6,5 m no nadir e de 5 m para o pixel ortorretificado. O sistema RapidEye também permite obter registros diários de qualquer ponto na superfície terrestre situado entre as latitudes  $-84^{\circ}$  e  $+84^{\circ}$  (BLACKBRIDGE, 2015). As imagens são obtidas em cinco bandas multiespectrais, sendo este o primeiro sensor a fornecer imagens na região denominada *red-edge*, situada entre a faixa de 690 a 730 nm do espectro eletromagnético (RAPIDEYE, 19--). Esta região tem auxiliado na caracterização da vegetação e, por isso, estas imagens têm sido aplicadas em estudos para o monitoramento de ambientes florestais, aprimorando os resultados obtidos (EITEL et al., 2011; SCHUSTER; FORSTER; KLEINSCHMIT, 2012; TILLACK et al., 2014).

Apesar de as imagens RapidEye apresentarem alta resolução espacial, viabilizando uma caracterização detalhada das feições na superfície terrestre, esta fonte de dados ainda é recente e, portanto, não permite a compreensão da dinâmica da cobertura da terra a longo prazo. Diante disso, embora sensores como *Thematic Mapper (TM)* e *Enhanced Thematic Mapper Plus (ETM<sup>+</sup>)* apresentem resoluções espacial e temporal inferiores, a utilização desses dados consiste em uma alternativa para a compreensão das mudanças na cobertura da Terra, devido à aquisição de informações há um período de tempo mais longo.

O programa Landsat, desenvolvido pela *National Aerospace and Space Administration (NASA)*, fornece informações da superfície terrestre desde 1972 (HANSEN; LOVELAND, 2012; WULDER et al., 2011). Além de representar a fonte de dados mais densa disponível e adquirida de forma sistemática, a resolução espacial dos atuais sensores em órbita fornece um detalhamento satisfatório da dinâmica da cobertura da terra, assim como das mudanças

ocorridas, com uma faixa de imageamento de 185x185 km (COHEN; GOWARD, 2004; WULDER; BUTSON; WHITE, 2008).

Em relação às características da resolução espectral do sensor TM a bordo dos satélites Landsat 4 e Landsat 5 e do sensor ETM<sup>+</sup> a bordo do Landsat 7, os quais são sensíveis a amplos intervalos do espectro eletromagnético (região do visível, infravermelho-próximo e infravermelho médio), as imagens provenientes destes sensores têm grande aplicabilidade em estudos para o monitoramento da vegetação (TIAN et al., 2013). Nesta perspectiva, dados TM/ETM<sup>+</sup> têm sido amplamente aplicados para o monitoramento do desmatamento e da expansão da fronteira agrícola (MICHALSKI; METZGER; PERES, 2010), assim como para o monitoramento de queimadas (JIN et al., 2013) e processos de distúrbios e regeneração florestal (KENNEDY; YANG; COHEN, 2010).

Entretanto, algumas falhas no sistema comprometeram a continuidade na disponibilização dos dados. O sensor TM apresentou algumas falhas no envio de dados em 1995 e também a partir de 2011, tendo seu funcionamento sido encerrado em novembro de 2012, enquanto o sensor *Enhanced Thematic Mapper* (ETM), a bordo do Landsat 6, falhou ao alcançar a órbita em 1993 (WULDER et al., 2012). Além disso, devido à baixa resolução temporal (16 dias), as condições atmosféricas podem dificultar a aquisição de imagens com baixa ocorrência de nuvens, principalmente para regiões tropicais.

Diante disso, a utilização de outros sensores remotos representa uma alternativa para a complementaridade de dados, auxiliando na compreensão da dinâmica das mudanças na superfície terrestre ao longo do tempo. Dessa maneira, considerando outros bancos de dados que também apresentam acesso aberto, destacam-se as imagens provenientes do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS). Este sensor está a bordo dos satélites Terra e Aqua, lançados pela NASA em 1999 e 2002, respectivamente (XIONG

et al., 2009). Os dados coletados integram o banco de dados do programa *Earth Observing System* (EOS), o qual tem o intuito de monitorar as dinâmicas na superfície terrestre, na atmosfera e nos oceanos (SAVTCHENKO et al., 2004). A resolução espectral destes instrumentos inclui 36 faixas do espectro eletromagnético, compreendidas entre a região do visível e infravermelho termal (0,407-14,385  $\mu\text{m}$ ) e com resolução espacial variando entre 250, 500 e 1.000 m. Além disso, o imageamento é realizado para uma área de 2.330 km, o que garante alta frequência temporal (ciclo de revisita de 1-2 dias) na aquisição de imagens. Estes dados são disponibilizados na forma de diferentes produtos, os quais incluem imagens de reflectância de superfície (produto MOD09), cobertura da terra (produto MOD12) e índices de vegetação (produto MOD13), entre outros.

#### 4.2 NDVI

O Índice de Vegetação da Diferença Normalizada, ou NDVI (ROUSE, 1974), sigla em inglês, corresponde à razão entre a diferença das bandas do infravermelho próximo (NIR) e do vermelho (R) e a soma do infravermelho próximo e do vermelho, como representado na seguinte equação:

$$\text{NDVI} = \frac{(\text{NIR}-\text{R})}{(\text{NIR}+\text{R})} \quad (1)$$

Este é um dos principais índices para realçar alterações na vegetação, devido ao seu comportamento contrastante nestas duas regiões do espectro eletromagnético, permitindo monitorar suas mudanças sazonais e interanuais (JENSEN, 2006). Além disso, por ser um índice que representa uma razão, a imagem resultante tem menor influência de ruídos decorrentes das condições

atmosféricas (diferenças no ângulo do sol, iluminação do terreno, sombra de nuvens), o que pode favorecer a sua aplicação em análises multissensor.

### **4.3 Pré-processamento: influência de fatores externos na resposta espectral**

Em análises de detecção de mudança, as etapas para correção geométrica e registro da imagem, correção radiométrica e atmosférica são fundamentais para a qualidade dos produtos obtidos por meio das análises de detecção de mudança (COPPIN et al., 2004; HUSSAIN et al., 2013; LU et al., 2004).

A existência de erros de registro pode comprometer os resultados obtidos por conduzir à detecção de falsas mudanças, devido à comparação entre áreas não correspondentes (FARIN; WITH, 2005). Diante disso, a correção geométrica e o registro das imagens são fundamentais para minimizar a influência do deslocamento entre imagens em relação à correta localização geográfica das feições na superfície terrestre (CHEN et al., 2012; FARIN; WITH, 2005).

A correção radiométrica, ou normalização dos dados, consiste na conversão dos números digitais para valores de radiância ou reflectância, permitindo análises quantitativas para um conjunto de imagens (LU et al., 2004). Os parâmetros desta conversão visam reduzir erros causados por variações nas características do sistema sensor e relacionados ao ângulo e à distância do Sol e, portanto, os valores obtidos representam a emitância/reflectância no topo da atmosfera (TOA) (CHEN; VIERLING; DEERING, 2005).

Entretanto, a atmosfera também influencia a resposta espectral das feições na superfície terrestre. Os efeitos, principalmente, da absorção e do espalhamento atmosférico provocado por gases, aerossóis, vapor d'água e partículas de poeira interferem nos valores registrados pelo sistema sensor

(JENSEN, 2006). Diante disso, para análises de detecção de mudança, a correção atmosférica é uma etapa fundamental para obter os valores de reflectância ao nível do solo, principalmente quando imagens de múltiplas datas ou provenientes de diferentes sensores são utilizadas (SONG et al., 2001).

Os métodos variam desde equações simples, como os métodos da subtração do objeto escuro e da combinação de histograma (HELMER; RUEFENACHT, 2007), até a utilização de modelos robustos, como, por exemplo, o modelo de transferência radioativa 6S (*Second simulation of the satellite signal in the solar spectrum*) (VERMOTE et al., 1997). A escolha do algoritmo para correção, geralmente, está relacionada à disponibilidade de informações sobre as condições atmosféricas durante o imageamento.

A influência atmosférica deve ser considerada, principalmente, em regiões tropicais, devido à grande incidência de nuvens e aerossóis. Além disso, o NDVI consiste em um dos principais índices utilizados para o monitoramento da vegetação e fatores atmosféricos podem influenciar a confiabilidade dos seus valores estimados (HILKER et al., 2012).

O efeito do espalhamento atmosférico é inversamente proporcional ao comprimento de onda no espectro eletromagnético e, embora a influência seja menor nas regiões do vermelho e infravermelho próximo (ROY et al., 2014), em estudos nos quais foram comparados os valores de NDVI, antes e após a correção atmosférica, foi demonstrado que há um aumento nos valores do índice após obter a reflectância ao nível do solo (ROY et al., 2014; XUE et al., 2014). Este resultado é decorrente do aumento do contraste entre as regiões do vermelho e infravermelho próximo, devido a um balanceamento entre os efeitos da absorção e espalhamento. Esta condição evidencia que a correção atmosférica pode ser útil para obter informações mais coerentes, em relação aos estágios da vegetação.

A realização desses pré-processamentos demonstra um dos principais desafios em análises de sensoriamento remoto, o qual consiste na maximização da relação sinal-ruído (COPPIN et al., 2004). Dessa maneira, em análises de detecção de mudança, estas etapas são fundamentais para que todas as informações extraídas a partir das imagens de satélite sejam representativas de fenômenos reais das feições na superfície terrestre.

#### **4.4 Detecção de mudança baseada em objeto**

Embora existam muitas técnicas, descritas na literatura, para a detecção de mudanças na cobertura da terra, tais como razão de imagem, imagem diferença, análise de componentes principais (COPPIN et al., 2004; LIU; NISHIYAMA; YANO, 2004; LU et al., 2004; SINGH, 1989), estas, geralmente, utilizam um pixel individual como unidade básica de análise. Entretanto, com a ampliação de sistemas sensores coletando informações da superfície terrestre, o uso de imagens de alta resolução espacial possibilita que as entidades geográficas sejam facilmente identificadas e individualizadas.

Uma abordagem baseada em objeto é aquela, na qual, por meio de técnicas de segmentação de imagens, pixels são agrupados de acordo com semelhanças em suas características geográfica, espectral e espacial, no intuito de representarem entidades geográficas identificáveis na superfície terrestre (CHEN et al., 2012). Vários trabalhos de revisão evidenciam as principais técnicas baseadas em pixel para a detecção de mudança e suas principais aplicações (COPPIN et al., 2004; LIU; NISHIYAMA; YANO, 2004; LU et al., 2004; SINGH, 1989), entretanto, independente da abordagem utilizada, questões críticas, como a influência do erro de registro e a existência de ruídos, afetam a qualidade dos resultados, devido ao fato de conduzirem à detecção de falsas mudanças.

Em análises baseadas em pixel é necessário que a acurácia do registro seja ao nível de subpixel (JIANYAA et al., 2008). Entretanto, os resultados, ainda assim, são influenciados pelo efeito *salt-pepper*, o qual é representado por ruídos aleatórios na imagem de mudança (DESCLÉE; BOGAERT; DEFOURNY, 2006; QIN et al., 2013). Contudo, Chen et al. (2012) evidenciaram que análises de detecção de mudança baseada em objeto apresentaram menor influência de erros de registro quando comparadas à análise baseada em pixel.

Dessa maneira, estudos utilizando uma abordagem baseada em objeto para detecção de mudança têm obtido resultados melhores quando comparados a análises de pixel, devido a uma menor influência dos fatores mencionados anteriormente (BONTEMPS et al., 2008; CHEN et al., 2012; DESCLÉE; BOGAERT; DEFOURNY, 2006; IM; JENSEN; TULLIS, 2008). Esta abordagem se mostra favorável para o monitoramento de mudanças das feições na superfície terrestre, como constatado em monitoramentos para áreas florestais (DESCLÉE et al., 2013; RAŠI et al., 2011) e áreas urbanas (DOXANI; KARANTZALOS; STRATI, 2012; NIEMEYER; MARPU; MARPU, 2008; ZHANG et al., 2014).

Imagens capturadas para uma mesma área geográfica, mas adquiridas em datas distintas, dificilmente representarão as feições da mesma maneira devido às condições atmosféricas, diferenças no ângulo de visada e variações na iluminação da superfície (WULDER; BUTSON; WHITE, 2008). Estes fatores podem influenciar o processo de segmentação das imagens multitemporais, determinando variações no tamanho e na forma dos objetos entre as datas distintas, mesmo quando estes representam a mesma feição geográfica (CHEN et al., 2012).

No intuito de eliminar a influência destes fatores, Desclée, Bogaert e Defourny (2006) apresentaram um algoritmo para a realização de uma segmentação

multidata, no qual imagens multitemporais são segmentadas juntas, produzindo objetos correspondentes em relação ao tamanho, à forma e à localização geográfica, em todas as datas avaliadas.

Entre as restrições para as análises de detecção de mudança, há a limitação na aquisição de informações no terreno, referente às classes de mudança na cobertura de terra para as múltiplas imagens (JENSEN, 2006). Além das questões de logística associadas ao tempo, ao esforço e ao custo para a coleta de informação de verdade de campo, em situações reais nem sempre é possível obter este conjunto de dados para todas as datas analisadas (BOVOLO et al., 2012). Diante disso, a utilização de técnicas não supervisionadas consiste em uma importante ferramenta, por não requerem informação, *a priori*, das mudanças ocorridas na cobertura da Terra (COPPIN, 2004).

Além disso, nas análises baseadas em objeto há uma variação no tamanho da unidade mínima de mapeamento, o que pode interferir no tipo e no tamanho das mudanças detectadas. Sulla-Menashe et al. (2014) demonstraram que, em uma série temporal MODIS/NBR (*Normalized Burn Ratio*) com resolução espacial de 500 m, o tamanho dos eventos de mudança influenciou o monitoramento dos distúrbios florestais, sendo detectados os eventos com, pelo menos, 0,3 do tamanho do pixel MODIS. As diferenças na magnitude das mudanças, ou seja, o grau de alteração dos valores de reflectância/radiância pode influenciar a capacidade dos diferentes sensores em detectá-las, assim como influenciar as análises das feições de acordo com o percentual de área que a mudança ocupa, dentro do objeto de interesse. Dessa maneira, compreender como estas variações influenciam as análises de detecção de mudança pode auxiliar no desempenho dos algoritmos utilizados.

#### 4.5 Abordagem multissensor para detecção de mudança

Com a ampliação das fontes de dados de diferentes satélites, novas metodologias utilizando uma abordagem multissensor têm sido propostas no intuito de combinar e maximizar a utilização destas informações provenientes de diferentes sistemas. Esta abordagem para a detecção de mudanças na cobertura da terra ainda é recente na literatura, com técnicas sendo aplicadas principalmente para a fusão ou a substituição de imagens.

A fusão corresponde a uma combinação entre medidas independentes obtidas por sensores distintos para gerar uma única imagem, geralmente combinando informações espectral e espacial (JENSEN, 2006). Esta metodologia também corresponde a uma alternativa para melhorar a performance dos algoritmos de detecção de mudança. Neste caso, esta abordagem tem sido aplicada para o monitoramento de mudanças relacionadas a análises de séries temporais, uma vez que, nestes estudos, é fundamental uma boa qualidade espaço-temporal das imagens disponíveis (VERGER; BARET; WEISS, 2011). Dessa maneira, técnicas têm sido desenvolvidas para combinar, por exemplo, a resolução espacial de imagens TM com a resolução temporal de dados MODIS (GAO et al., 2006; HILKER et al., 2009a, 2009b), o que permite obter um denso conjunto de dados ao longo do tempo e com baixa influência de nuvens, sendo, portanto, favorável para o monitoramento das mudanças em ambientes tropicais.

A substituição é utilizada, principalmente, em análises com imagens provenientes de sensores ópticos, os quais são mais influenciados pelas condições atmosféricas, sendo uma alternativa para quando ocorrem falhas no sistema sensor, o que conduz a uma ausência de registros ou à produção de imagens com ruídos (XAUD, 2013). Contudo, na inserção desses dados auxiliares é fundamental que estes apresentem uma resposta equivalente à

informação da imagem substituída. Esta alternativa tem sido aplicada, principalmente, para análises que utilizam dados TM/ETM<sup>+</sup>, nos quais há uma recorrência na descontinuidade de registros.

A aplicação desta abordagem multissensor evidenciou uma boa concordância para a detecção de mudanças integrando dados TM e AWiFIS, (CHEN et al., 2013; QIN et al., 2013). Além disso, Desclée et al. (2013) evidenciaram que a acurácia de mapeamentos para a detecção de mudança, utilizando imagens *Disaster Monitoring Constellation* (DMC) como alternativa à ausência de registros de imagens TM, forneceu resultados semelhantes aos anteriormente obtidos utilizando apenas imagens provenientes do mesmo sensor, demonstrando a aplicabilidade desta abordagem. Qin et al. (2013) também apresentaram mapeamentos com acurácia satisfatória, considerando imagens TM e IRS LISS3 para a detecção de mudanças, em que as imagens foram empilhadas juntas e o algoritmo de classificação aplicado uma única vez.

A possibilidade de substituição de imagens TM/ETM<sup>+</sup> é fundamental em estudos para o monitoramento de mudanças em florestais tropicais em que, embora exista um extenso arquivo de dados possibilitando a compreensão da dinâmica destes ambientes, a influência de nuvens e neblina ao longo de todo o ano consiste em um fator limitante na qualidade das imagens disponíveis (DESCLÉE et al., 2013). Dessa maneira, para garantir um monitoramento global destes ecossistemas, é inevitável a utilização de imagens de múltiplos sensores. Neste caso, projetos como o desenvolvido pelo *Tropical Ecosystem Environment Observation by Satellite* (TREES), o qual, por meio de amostragens sistemáticas obtidas em uma escala pan-tropical, fornece estimativas desde 1990 das mudanças na cobertura florestal, assim como das taxas de emissão de carbono, por meio da combinação de imagens TM/ETM<sup>+</sup>, AVNIR-2, DMC e Kompsat (RAŠI et al., 2013; VOLMAR et al., 2013).

Além destas alternativas, a complementação de dados multissensor também representa uma importante ferramenta para análises de detecção de mudança. Embora já existam metodologias para as etapas de pré-processamento para melhoria da combinação destes dados (JI; GALLO, 2006; WULDER; BUTSON; WHITE, 2008), estudos comparando as respostas de diferentes sensores para um mesmo objeto de estudo ainda são escassos (QIN et al., 2013). Neste caso, a combinação de informações referentes às características das mudanças de interesse com o potencial de diferentes sensores remotos em detectá-las pode subsidiar a formação de um banco de dados capaz de evidenciar o nível de detalhamento necessário para o monitoramento de distintas alterações na cobertura da terra, conduzindo a uma maior confiabilidade dos resultados produzidos.

#### **4.6 Matriz de confusão**

A exatidão dos resultados provenientes das análises de detecção de mudança depende da realização das etapas de pré-processamento para eliminar a influência de fatores externos, a fim de melhorar a relação sinal-ruído da resposta espectral (COPPIN et al., 2004). Além disso, fatores associados à complexidade e ao conhecimento do analista da área monitorada, à disponibilidade de informações de verdade de campo, assim como das restrições dos algoritmos aplicados, podem influenciar os resultados obtidos (LU et al., 2004).

Dessa maneira, a matriz de confusão consiste em um importante parâmetro para a avaliação da qualidade da análise realizada. Neste caso, ela é calculada baseando-se na relação entre os resultados obtidos de forma automática com as informações de referência, correspondentes à verdade de campo (STEHMAN, 2000).

No cruzamento destas informações, a diagonal central da matriz representa a relação de acerto total entre as informações obtidas automaticamente e as informações de referência. Além disso, a partir dos totais marginais das linhas e colunas, também é possível calcular a probabilidade de acerto individual para cada classe avaliada (STORY; CONGALTON, 1986).

Neste caso, pode ser obtida a acurácia do produtor, correspondente à probabilidade de um dado de referência ter sido classificado corretamente na análise automática (ANTUNES; LINGNAU, 1997). Associado a este parâmetro, é possível calcular o erro de omissão, o qual se refere aos dados de referência que não foram atribuídos à sua respectiva categoria, na classificação automática (BRITO, 2009).

De maneira similar, também pode ser extraída a acurácia do usuário, a qual representa a probabilidade de uma determinada classe representar esta mesma categoria em uma verificação de campo. Combinado a esta medida, é possível calcular o erro de comissão, o qual se refere à atribuição incorreta de um determinado dado a uma classe, à qual ele não pertence (BRITO, 2009).

A combinação e a interpretação de todos estes parâmetros são fundamentais em análises de detecção de mudança, uma vez que, a partir destes valores, é possível verificar a qualidade e o grau de concordância dos resultados obtidos em relação às informações de referência e, portanto, estes parâmetros podem auxiliar no direcionamento das metodologias aplicadas.

#### **4.7 Séries temporais para detecção de mudanças na vegetação**

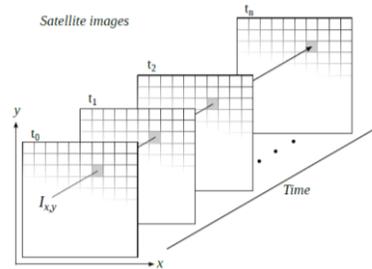
Análises de detecção de mudança podem ser realizadas utilizando-se duas ou mais imagens para uma mesma área na superfície terrestre, no intuito de identificar as alterações na paisagem ocorridas neste período (HUSSAIN et al., 2013). A abordagem bitemporal, muitas vezes, é limitada pelo banco de imagens

disponíveis, e a aquisição de imagens em datas aniversariantes consiste em uma das principais condições para a detecção de mudança na vegetação. A dinâmica sazonal pode conduzir a alterações no padrão de reflectância dos alvos de interesse, o que pode interferir em suas respostas espectrais (LU et al., 2004). As diferenças no imageamento ocorridas por variações sazonais podem influenciar as assinaturas espectrais, dificultando a distinção entre distúrbios naturais e antrópicos, o que pode reduzir a confiabilidade dos resultados obtidos (COPPIN et al., 2004).

Para regiões tropicais, o emprego de metodologias que utilizam uma abordagem bitemporal é influenciado pela alta frequência de nuvens, sendo um fator limitante para a disponibilidade e a escolha das imagens ao longo do período avaliado. Dessa maneira, a análise utilizando apenas uma diferença entre duas datas, a partir de imagens de períodos não correspondentes, pode conduzir à detecção de mudanças que são resultantes de alterações fenológicas e não mudanças no tipo de cobertura da Terra (VERBESSELT, 2010a, VERBESSELT, 2010b).

A definição de mudanças na cobertura da terra, representada como um contraste entre dois parâmetros pontuais no tempo, pode simplificar a percepção da dinâmica ao longo do tempo e, muitas vezes, ocultar o processo gradual dessas alterações (KENNEDY; YANG; COHEN, 2010). Diante disso, atualmente, há uma tendência na comunidade científica para o uso de uma abordagem multitemporal (DEVRIES et al., 2015; DUTRIEUX et al., 2015; VERBESSELT, 2010a, 2010b). Uma série temporal pode ser definida como um conjunto de observações ordenadas no tempo (MORETTIN; TOLOI, 2004). Na perspectiva da análise de dados de sensoriamento remoto, esta definição corresponde à aquisição de informações por um conjunto de imagens de satélite em diferentes períodos no tempo para uma mesma extensão espacial, a qual é representada pelo pixel (Figura 1).

Figura 1 - Construção de uma série temporal a partir de imagens de satélite, na qual o comportamento de cada pixel é avaliado ao longo do tempo. Adaptado de Maus (2014).



Em uma perspectiva de análise de dados de sensoriamento remoto, métodos baseados nas trajetórias temporais têm sido desenvolvidos nos anos recentes. Entre as metodologias propostas na literatura, podem-se destacar:

- a) *Breaks For Additive Seasonal and Trend*, ou **BFAST**: a partir da decomposição de séries temporais, Verbesselt et al. (2010a), desenvolveram esta metodologia a fim de caracterizar as mudanças na cobertura da Terra. Os diferentes tipos de mudanças são classificados de acordo com suas características dentro destas componentes. Mudanças abruptas e graduais, geralmente, são identificadas pela componente de tendência, enquanto mudanças fenológicas estão associadas à componente sazonal. As componentes de tendência e sazonalidade são estimadas iterativamente para identificação de quebras (*breakpoints*) ao longo da série temporal, as quais indicam a ocorrência de uma mudança;
- b) *Landsat-based Detection of Trends in Disturbance and Recovery*, ou **LandTrendr**: este algoritmo aplicado por Kennedy, Yang e Cohen (2010) utiliza uma abordagem de segmentação temporal, na qual são extraídas trajetórias espectrais das mudanças na superfície terrestre, com base no conjunto de imagens Landsat. A construção

da série temporal baseia-se na variação interanual, na qual a trajetória temporal é construída considerando o melhor valor de cada pixel em cada ano, reduzindo a influência de ruídos, como nuvens e sombras. A partir disso, são produzidos segmentos das trajetórias de cada pixel, permitindo caracterizar o processo de mudança ao longo do tempo, identificando processos graduais como regeneração e processos abruptos como a ocorrência de corte raso;

- c) *Vegetation Change Tracker*, ou **VCT**: a metodologia proposta por Huang et al. (2010) é baseada nas propriedades espectro-temporais para detectar distúrbios na vegetação. Neste caso, o componente espectral considera que ambientes sem ocorrência de distúrbios devem apresentar um comportamento estável, enquanto áreas não florestais têm uma maior variabilidade sazonal e interanual. A fim de medir a verossimilhança, amostras de vegetação são coletadas para o cálculo de vários índices, os quais são indicativos da probabilidade de cada pixel corresponder a um pixel florestal. Estes índices são utilizados como parâmetros para a construção da série temporal. No intuito de substituir pixels mascarados devido à ocorrência da presença de nuvens ou sombra, uma interpolação temporal é aplicada, na qual o novo valor é obtido, considerando as observações livres de nuvens mais próximas, antes e após do pixel avaliado;
- d) *Continuous Monitoring of Forest Disturbance Algorithm*, ou **CMFDA**: o método proposto por Zhu, Woodcock e Olofsson (2012) utiliza a predição de imagens Landsat para identificar distúrbios florestais, a partir da comparação com os valores observados. Um modelo de superfície de reflectância é ajustado em função de senos e cossenos para cada pixel em cada banda

espectral, incluindo dois termos harmônicos e um modelo de mudança interanual. Um pixel é identificado como distúrbio de acordo com a frequência em que este comportamento é observado consecutivamente ao longo do tempo. Entretanto, a capacidade de detecção de mudança do algoritmo é dependente do número de observações sem ruídos;

- e) *Spectral–Temporal Analysis by Response Surface*, ou **STARS**: Mello et al. (2013) desenvolveram este algoritmo para explorar o comportamento espectral dos alvos de interesse ao longo do tempo, fundamentando-se na resposta de uma superfície espectro-temporal. A partir da análise de  $n$ -datas, é formado um espaço espectro-temporal tridimensional, no qual, para cada pixel, são extraídas as variáveis independentes tempo e espectro e a variável dependente, representada pelos valores de reflectância ou índices espectrais. A escolha do tipo de modelo para ajuste desta superfície é determinada de acordo com o banco de dados utilizado e a finalidade de aplicação destes dados. Este conjunto de informações é sintetizado em uma única imagem multicoeficiente, facilitando a compreensão do banco de dados analisado. Além disso, o método permite utilizar observações de diferentes sensores com diferentes comprimentos de onda e em intervalos irregulares de tempo;
- f) *Continuous Change Detection and Classification*, ou **CCDC**: Zhu e Woodcock (2014) desenvolveram esta metodologia que pode ser aplicada para detectar diferentes tipos de mudanças. O termo contínuo refere-se à capacidade do algoritmo em detectar mudanças a cada inserção de uma nova imagem. A fim de detectar mudanças intraanuais, interanuais graduais e mudanças abruptas, um modelo para a série temporal é ajustado, considerando os parâmetros de

sazonalidade, tendência e *breakpoint*. A detecção de mudanças é resultado da comparação entre valores preditos pelo ajuste do modelo com os valores observados. Na classificação temática, este método distingue-se dos convencionais, uma vez que utiliza os coeficientes dos modelos das séries temporais como parâmetros de entrada para caracterizar as classes de cobertura da terra. Entretanto, a necessidade de uma alta frequência de observações sem nuvens e as exigências computacionais para armazenamento de dados representam fatores limitantes para sua aplicação.

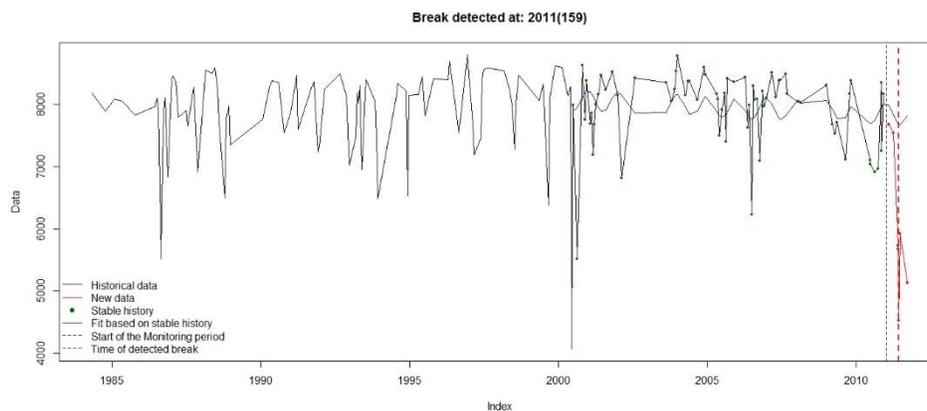
#### **4.8 BFAST Monitor**

O algoritmo *Breaks For Additive Season and Trend Monitor*, ou BFAST Monitor, é uma extensão do conceito do BFAST descrito anteriormente, o qual é apropriado para caracterizar mudanças associadas à tendência e à sazonalidade em uma série temporal histórica. No entanto, ele não é adequado para detectar distúrbios em um banco de dados recente. Diante disso, na nova abordagem, Verbesselt, Zeileis e Herold (2012) aprimoraram o algoritmo para a detecção de mudanças abruptas no final da trajetória temporal.

A série temporal é dividida em um período histórico e um período de monitoramento. A análise consiste em obter um modelo de regressão ajustado a partir das componentes de tendência e/ou sazonalidade para o conjunto de dados identificado como período histórico estável. A identificação deste período é fundamental para distinguir as mudanças entre naturais e abruptas (mudanças de interesse). Posteriormente, a estabilidade deste modelo é testada para o conjunto de dados do período de monitoramento. Se a hipótese de estabilidade estrutural for rejeitada, um *breakpoint* (possível mudança) será detectado (Figura 2).

O algoritmo foi testado, inicialmente, para séries temporais MODIS/NDVI de um ambiente controlado (dados simulados) e para uma condição real de mudanças decorrentes de um período de seca em uma região na Somália (VERBESSELT; ZEILEIS; HEROLD, 2012). Ambos os casos evidenciaram que o algoritmo foi robusto para a detecção de distúrbios florestais.

Figura 2 - Análise a partir do pacote bfastSpatial disponível para o software R. Resultado do BFAST Monitor para a trajetória temporal de um pixel no qual um breakpoint foi detectado.



Um fator relevante no BFAST Monitor para a distinção entre áreas de mudança e não mudança consiste na relação sinal-ruído (VERBESSELT; ZEILEIS; HEROLD, 2012). Diante disso, Schultz et al. (2015) testaram como três diferentes métodos de correção radiométrica (LEDAPS, ATCOR 2 & 3, e DOS) influenciaram a detecção de desmatamentos utilizando séries temporais Landsat, para locais distintos no Brasil, na Etiópia e no Vietnã. As principais fontes de erros foram associadas à variância dos dados, à disponibilidade de imagens, à contaminação atmosférica e aos efeitos de borda. Além disso, os resultados evidenciaram uma acurácia semelhante para as séries temporais corrigidas aplicando os algoritmos LEDAPS e ATCOR. No entanto, os autores

ressaltam que o método DOS não é recomendado para o mapeamento de desmatamentos em florestas tropicais.

Entre as vantagens do algoritmo, é importante ressaltar que este pode ser aplicado para séries temporais com uma frequência irregular de observações. Esta condição é relevante em ambientes tropicais, uma vez que a grande incidência de nuvens corresponde a um fator limitante para a disponibilidade de imagens nestas regiões. Neste contexto, DeVries et al. (2015) utilizaram uma série temporal ETM<sup>+</sup> para monitorar distúrbios em uma floresta tropical montana na Etiópia. A partir de monitoramentos sequenciais em intervalos de um ano, os resultados evidenciaram que o algoritmo foi capaz de detectar pequenos distúrbios florestais, mesmo em regiões com uma baixa densidade de dados.

Além destes trabalhos que têm demonstrado a aplicabilidade deste algoritmo para o monitoramento de ecossistemas tropicais, estudos recentes também têm aprimorado o banco de dados para a construção das séries temporais avaliadas, no intuito de melhorar a acurácia da detecção das mudanças na vegetação. Em contraste com as imagens de radar, a qualidade das imagens provenientes de sensores ópticos tem grande influência das condições atmosféricas. Diante disso, Reiche et al. (2015) utilizaram uma abordagem multissensor para a fusão de imagens Landsat/NDVI e ALOS PALSAR. Em seguida, este banco de dados foi analisado utilizando-se o BFAST Monitor, para o monitoramento de desmatamentos em uma floresta plantada nos trópicos. Os resultados evidenciaram uma melhoria na detecção das mudanças de interesse a partir desta abordagem multissensor.

O algoritmo também foi aplicado para o monitoramento de regiões com alta variabilidade interanual. Neste caso, Dutriux et al. (2015) avaliaram uma floresta tropical seca na Bolívia. No intuito de reduzir a interferência das condições ambientais, uma série temporal MODIS/NDVI foi incluída como um regressor externo ao modelo ajustado para a série temporal TM/ETM<sup>+</sup>. A

inserção deste parâmetro influenciou positivamente a sensibilidade do algoritmo, no qual o uso do contexto espacial desta série temporal melhorou a distinção entre mudanças naturais e antropogênicas. Hamunyela, Verbesselt e Herold (2016), para reduzir a influência da sazonalidade em séries temporais, também utilizaram o contexto espacial. Nesta abordagem, cada pixel da imagem é espacialmente normalizado utilizando o valor da mediana, a qual é calculada a partir dos pixels vizinhos. O método foi testado para uma floresta tropical úmida no Brasil e uma floresta tropical seca na Bolívia. Para ambos os sistemas florestais não houve uma diferença significativa na acurácia global em relação aos desmatamentos, detectados pelo BFAST Monitor. No entanto, esta abordagem foi relevante para a floresta tropical seca, a qual é caracterizada por uma sazonalidade marcante. Neste caso, foi observada uma redução no atraso da detecção dos desmatamentos.

Diante deste embasamento teórico, observa-se que há um direcionamento na literatura para a formulação de alternativas que melhorem a capacidade de detecção de mudanças deste algoritmo. Além disso, nota-se uma tendência da sua aplicação em ecossistemas tropicais, o que consiste em um respaldo para a sua aplicação no monitoramento das formações florestais do território nacional. Neste contexto, neste estudo também fundamentado na análise de séries temporais pelo BFAST Monitor, é proposta uma metodologia a partir da integração de imagens de média e a alta resolução espacial para aprimorar a precisão dos monitoramentos dos desmatamentos na Mata Atlântica.

## REFERÊNCIAS

ANTUNES, A. F. B.; LINGNAU, C. Uso dos índices de acurácia para avaliação de mapas temáticos obtidos por meios de classificação digital. In: CONGRESSO E FEIRA PARA USUÁRIO DE GEOPROCESSAMENTO, 3., 1997, Curitiba. **Anais...** Curitiba: Sagres, 1997. 1 CD-ROM.

BLACKBRIDGE. **Satellite imagery product specifications**. Berlin, 2015. 48 p.

BONTEMPS, S. et al. An object-based change detection method accounting for temporal dependences in time series with medium to coarse spatial resolution. **Remote Sensing of Environment**, New York, v. 112, n. 6, p. 3181-3191, June 2008.

BOVOLO, F. et al. A framework for automatic and unsupervised detection of multiple changes in multitemporal images. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 50, n. 6, p. 2196-2212, 2012.

BRITO, A. de. **Acurácia e precisão do mapeamento da flora nativa e dos reflorestamentos de Minas Gerais**. 2008. 110 p. Dissertação (Mestrado em Engenharia Florestal)-Universidade Federal de Lavras, Lavras, 2009.

CHEN, G. et al. International journal of remote object-based change detection. **International Journal of Remote Sensing**, Basingstoke, v. 33, n. 14, p. 37-41, 2012.

CHEN, X. et al. Cross-sensor comparisons between Landsat 5 TM and IRS-P6 AWiFS and disturbance detection using integrated Landsat and AWiFS time-series images. **International Journal of Remote Sensing**, Basingstoke, v. 34, n. 7, p. 2432-2453, Apr. 2013.

CHEN, X.; VIERLING, L.; DEERING, D. A simple and effective radiometric correction method to improve landscape change detection across sensors and across time. **Remote Sensing of Environment**, New York, v. 98, n. 1, p. 63-79, Sept. 2005.

COHEN, W. B.; GOWARD, S. N. Landsat's role in ecological applications of remote sensing. **BioScience**, Washington, v. 54, n. 6, p. 535-545, June 2004.

COPPIN, P. et al. Review article digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 9, p. 1565-1596, May 2004.

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, New York, v. 102, n. 1/2, p. 1-11, 2006.

DESCLÉE, B. et al. Multi-sensor monitoring system for forest cover change assessment in Central Africa. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 6, n. 1, p. 110-120, 2013.

DEVRIES, B. et al. Robust monitoring of small-scale forest disturbances in a tropical montane forest using landsat time series. **Remote Sensing of Environment**, New York, v. 161, p. 107-121, May 2015.

DOXANI, G.; KARANTZALOS, K.; STRATI, M. T. Monitoring urban changes based on scale-space filtering and object-oriented classification. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 15, p. 38-48, Apr. 2012.

DUTRIEUX, L. P. et al. Monitoring forest cover loss using multiple data streams, a case study of a tropical dry forest in Bolivia. **ISPRS Journal of Photogrammetry and Remote Sensing**, Beijing, v. 107, p. 112-125, Sept. 2015.

EITEL, J. U. H. et al. Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. **Remote Sensing of Environment**, New York, v. 115, n. 12, p. 3640-3646, Dec. 2011.

FARIN, D.; WITH, P. H. N. de. Misregistration errors in change detection algorithms and how to avoid them. **International Conference on Image Processing (ICIP)**, Genova, v. 2, p. 438-441, Sept. 2005.

FEARNSIDE, P. M. The roles and movements of actors in the deforestation of Brazilian Amazonia. **Ecology and Society**, Wolfville, v. 13, n. 1, p. 23, 2008.

FOLEY, J. A. et al. Global consequences of land use. **Science**, New York, v. 309, n. 5734, p. 570-574, July 2005.

GAO, F. et al. On the blending of the landsat and MODIS surface reflectance: predicting daily landsat surface reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 44, n. 8, p. 3287-3319, Oct. 2006.

HAMUNYELA, E.; VERBESSELT, J.; HEROLD, M. Using spatial context to improve early detection of deforestation from Landsat time series. **Remote Sensing of Environment**, New York, v. 172, p. 126-138, Jan. 2016.

HANSEN, M. C.; LOVELAND, T. R. A review of large area monitoring of land cover change using Landsat data. **Remote Sensing of Environment**, New York, v. 122, p. 66-74, July 2012.

HELMER, E. H.; RUEFENACHT, B. A comparison of radiometric normalization methods when filling cloud gaps in Landsat imagery. **Canadian Journal of Remote Sensing**, Ottawa, v. 33, n. 4, p. 325-340, June 2007.

HILKER, T. et al. Generation of dense time series synthetic Landsat data through data blending with MODIS using a spatial and temporal adaptive reflectance fusion model. **Remote Sensing of Environment**, New York, v. 113, n. 9, p. 1988-1999, Sept. 2009a.

HILKER, T. et al. A new data fusion model for high spatial- and temporal-resolution mapping of forest disturbance based on Landsat and MODIS. **Remote Sensing of Environment**, New York, v. 113, n. 8, p. 1613-1627, Aug. 2009b.

HILKER, T. et al. Remote sensing of tropical ecosystems: atmospheric correction and cloud masking matter. **Remote Sensing of Environment**, New York, v. 127, p. 370-384, Dec. 2012.

HUANG, C. et al. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. **Remote Sensing of Environment**, New York, v. 114, p. 183-198, Jan. 2010.

HUSSAIN, M. et al. Change detection from remotely sensed images: from pixel-based to object-based approaches. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 80, p. 91-106, June 2013.

IM, J.; JENSEN, J. R.; TULLIS, J. A. Object-based change detection using correlation image analysis and image segmentation. **International Journal of Remote Sensing**, Basingstoke, v. 29, n. 2, p. 399-423, Jan. 2008.

JENSEN, J. R. **Remote sensing of the environment: an Earth Resource perspective.** 2<sup>nd</sup> ed. Upper Saddle River: Pearson Prentice Hall, 2006. 208 p. (Prentice Hall Series in Geographic Information Science).

JI, L.; GALLO, K. An agreement coefficient for image comparison. **Photogrammetric Engineering & Remote Sensing**, Falls Church, v. 72, n. 7, p. 823-833, July 2006.

JIANYAA, G. et al. A review of multi-temporal remote sensing data change detection algorithms. In: INTERNATIONAL SOCIETY FOR PHOTOGRAMMETRY AND REMOTE SENSING CONGRESS, 2008, Beijing. **Proceedings...** Beijing: ISPRS, 2008. p. 757-762.

JIN, S. et al. A comprehensive change detection method for updating the National Land Cover Database to circa 2011. **Remote Sensing of Environment**, New York, v. 132, p. 159-175, May 2013.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1., LandTrendr - temporal segmentation algorithms. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2897-2910, Dec. 2010.

LIU, Y.; NISHIYAMA, S.; YANO, T. Analysis of four change detection algorithms in bi-temporal space with a case study. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 11, p. 2121-2139, June 2004.

LU, D. et al. Change detection techniques. **International Journal of Remote Sensing**, Basingstoke, v. 25, n. 12, p. 2365-2401, June 2004.

MAUS, V. **Satellite time series analysis for land use/cover change detection.** Laxenburg: International Institute for Applied Systems Analysis, 2014. 16 p.

MELLO, M. et al. STARS: a new method for multitemporal remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 5, n. 4, p. 1897-1913, Apr. 2013.

MICHALSKI, F.; METZGER, J. P.; PERES, C. A. Rural property size drives patterns of upland and riparian forest retention in a tropical deforestation frontier. **Global Environmental Change**, Oxford, v. 20, n. 4, p. 705-712, Oct. 2010.

MORETTIN, P. A.; TOLOI, C. M. C. Preliminares. In: MIGON, H. (Ed.). **Análise de séries temporais**. São Paulo: E. Blücher, 2004. p. 1-20.

MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, London, n. 403, p. 853-858, Dec. 2000.

NIEMEYER, I.; MARPU, P. R.; MARPU, P. R. Change detection using object features. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Ed.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer Verlag, 2008. p. 185-201.

OLIVEIRA-FILHO, F. J. B.; METZGER, J. P. Thresholds in landscape structure for three common deforestation patterns in the Brazilian Amazon. **Landscape Ecology**, Dordrecht, v. 21, n. 7, p. 1061-1073, Oct. 2006.

QIN, Y. et al. Object-based land cover change detection for cross-sensor images. **International Journal of Remote Sensing**, Basingstoke, v. 34, n. 19, p. 6723-6737, Oct. 2013.

RAPIDEYE. **The rapideye red edge band**. Berlin, [19--]. 6 p.

RAŠI, R. et al. An automated approach for segmenting and classifying a large sample of multi-date Landsat imagery for pan-tropical forest monitoring. **Remote Sensing of Environment**, New York, v. 115, n. 12, p. 3659-3669, Dec. 2011.

RAŠI, R. et al. Automatic updating of an object-based tropical forest cover classification and change assessment. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 6, n. 1, p. 66-73, 2013.

REICHE, J. et al. Fusing Landsat and {SAR} time series to detect deforestation in the tropics. **Remote Sensing of Environment**, New York, v. 156, p. 276-293, Jan. 2015.

RIBEIRO, M. C. et al. The Brazilian Atlantic Forest: how much is left, and how is the remaining forest distributed?: implications for conservation. **Biological Conservation**, Essex, v. 142, n. 6, p. 1141-1153, June 2009.

ROUSE, J. W. Monitoring the vernal advancement and retrogradation of natural vegetation. **Remote Sensing Center**, Greenbelt, p. 1-8, 1974.

ROY, D. P. et al. Landsat-8: science and product vision for terrestrial global change research. **Remote Sensing of Environment**, New York, v. 145, p. 154-172, Apr. 2014.

RUDEL, T. K. et al. Changing drivers of deforestation and new opportunities for conservation. **Conservation Biology**, Essex, v. 23, n. 6, p. 1396-1405, Dec. 2009.

SAVTCHENKO, A. et al. Terra and aqua MODIS products available from NASA GES DAAC. **Advances in Space Research**, Oxford, v. 34, n. 4, p. 710-714, Jan. 2004.

SCHULTZ, M. et al. Error sources in deforestation detection using BFAST Monitor on Landsat time series across three tropical sites. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 9, n. 8, p. 3667-3679, Aug. 2015.

SCHUSTER, C.; FORSTER, M.; KLEINSCHMIT, B. Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. **International Journal of Remote Sensing**, Basingstoke, v. 33, n. 17, p. 5583-5599, Mar. 2012.

SINGH, A. Review article digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, Basingstoke, v. 10, n. 6, p. 989-1003, June 1989.

SONG, C. et al. Classification and change detection using Landsat TM Data: when and how to correct atmospheric effects? **Remote Sensing of Environment**, New York, v. 75, n. 2, p. 230-244, Feb. 2001.

STEHMAN, S. V. Practical implications of design-based sampling inference for thematic map accuracy assessment. **Remote Sensing of Environment**, New York, v. 72, n. 99, p. 35-45, Apr. 2000.

STEPHAN, C. **Automating near real-time deforestation monitoring with satellite image time series**. 2015. 121 p. Thesis (Master of Science in Geoinformatics)-University of Muenster, Muenster, 2015.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 52, n. 3, p. 397-399, Jan. 1986.

- SULLA-MENASHE, D. et al. Detecting forest disturbance in the Pacific Northwest from MODIS time series using temporal segmentation. **Remote Sensing of Environment**, New York, v. 151, p. 114-123, Aug. 2014.
- TEIXEIRA, A. M. G. et al. Modeling landscape dynamics in an Atlantic Rainforest region: implications for conservation. **Forest Ecology and Management**, Amsterdam, v. 257, n. 4, p. 1219-1230, Feb. 2009.
- TIAN, F. et al. Mapping and evaluation of NDVI trends from synthetic time series obtained by blending landsat and MODIS data around a coalfield on the loess Plateau. **Remote Sensing**, Washington, v. 5, n. 9, p. 4255-4279, Sept. 2013.
- TILLACK, A. et al. Estimation of the seasonal leaf area index in an alluvial forest using high-resolution satellite-based vegetation indices. **Remote Sensing of Environment**, New York, v. 141, p. 52-63, Feb. 2014.
- VERBESSELT, J. et al. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 1, p. 106-115, Jan. 2010a.
- VERBESSELT, J. et al. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2970-2980, Dec. 2010b.
- VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, New York, v. 123, p. 98-108, Aug. 2012.
- VERGER, A.; BARET, F.; WEISS, M. A multisensor fusion approach to improve LAI time series. **Remote Sensing of Environment**, New York, v. 115, n. 10, p. 2460-2470, Oct. 2011.
- VERMOTE, E. F. et al. Second simulation of the satellite signal in the solar spectrum, 6S: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 35, n. 3, p. 675-686, 1997.
- VOLMAR, M. et al. Combining Landsat TM/ETM+ and ALOS AVNIR-2 satellite data for tropical forest cover change detection. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 6, n. 1, p. 102-109, Feb. 2013.

WOODCOCK, C. et al. Free access to Landsat imagery teach by the book science education . **Science**, New York, v. 320, n. 5879, p. 1011-1012, May 2008.

WULDER, M. A.; BUTSON, C. R.; WHITE, J. C. Cross-sensor change detection over a forested landscape: options to enable continuity of medium spatial resolution measures. **Remote Sensing of Environment**, New York, v. 112, n. 3, p. 796-809, Mar. 2008.

WULDER, M. A. et al. Continuity of Landsat observations: short term considerations. **Remote Sensing of Environment**, New York, v. 115, n. 2, p. 747-751, Feb. 2011.

WULDER, M. A. et al. High spatial resolution remotely sensed data for ecosystem characterization. **BioScience**, Washington, v. 54, n. 6, p. 511-521, 2004.

WULDER, M. A. et al. Opening the archive: how free data has enabled the science and monitoring promise of Landsat. **Remote Sensing of Environment**, New York, v. 122, p. 2-10, July 2012.

XAUD, M. R. **Dinâmica do uso e cobertura da terra na região sudeste de Roraima através de técnicas de detecção de mudanças**. 2013. 135 p. Tese (Doutorado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

XIONG, X. et al. NASA EOS Terra and Aqua MODIS on-orbit performance. **Advances in Space Research**, Oxford, v. 43, n. 3, p. 413-422, Feb. 2009.

XUE, X. et al. Case study of atmospheric correction on CCD data of HJ-1 satellite based on 6S model. **IOP Conference Series: Earth and Environmental Science**, Waterloo, v. 17, p. 12215, Mar. 2014.

ZHANG, Y. et al. Quantification of anthropogenic and natural changes in oil sands mining infrastructure land based on RapidEye and SPOT5. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 29, p. 31-43, June 2014.

ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, New York, v. 144, p. 152-171, Mar. 2014.

ZHU, Z.; WOODCOCK, C. E.; OLOFSSON, P. Continuous monitoring of forest disturbance using all available Landsat imagery. **Remote Sensing of Environment**, New York, v. 122, p. 75-91, July 2012.

## CAPÍTULO 2

### Uso de séries temporais TM/RapidEye para a detecção de desmatamentos na Mata Atlântica

#### RESUMO

O desmatamento de florestas tropicais corresponde a uma das principais ameaças antrópicas para a manutenção da estabilidade destes ecossistemas. Portanto, o monitoramento destas regiões é fundamental para acompanhar as mudanças nestes ambientes. Neste contexto, séries temporais são importantes subsídios para compreender a dinâmica dos ecossistemas florestais. Entretanto, as metodologias são baseadas, principalmente, em pixel e utilizando imagens de um mesmo sensor. O objetivo, neste trabalho, foi propor uma nova metodologia utilizando séries temporais multissensor baseadas em objeto, para reduzir o tempo computacional e melhorar a precisão da detecção automática de pequenos desmatamentos, aplicando o algoritmo BFAST Monitor. O estudo foi desenvolvido em uma área do bioma Mata Atlântica no estado de Santa Catarina, região sul do Brasil. Devido à alta similaridade espectral, os desmatamentos foram caracterizados como a remoção da cobertura florestal da vegetação nativa ou plantada. Foram adquiridas 230 imagens TM (órbita/ponto 227/068), entre 1984 e 2011 e 20 imagens RapidEye (tile 2226122), entre 2009 e 2011. A partir de uma segmentação multidata, a área de estudo foi delimitada em 1.972 objetos. Em seguida, foram extraídos os valores do NDVI médio e mínimo de todos os objetos, em todas as imagens de ambos os sensores. Este banco de dados foi a referência para a construção das imagens-objeto TM e RapidEye. Nesta abordagem, o valor de cada pixel é correspondente ao valor do parâmetro estatístico atribuído a cada objeto. Com esta metodologia, o banco de dados foi reduzido em 97%. Posteriormente, estas imagens foram utilizadas para a construção das oito séries temporais avaliadas no BFAST Monitor. O período histórico foi definido, inicialmente, apenas com as imagens TM entre 1984 e 2010. Em seguida, este período foi constituído por imagens TM entre 1984 e 2008 e RapidEye, entre 2009 e 2010. O período de monitoramento (2011) foi fixado como sendo constituído por imagens TM e RapidEye, separadamente. A comparação do tempo médio para o processamento da série temporal em pixel em relação à abordagem baseada em objeto evidenciou um decréscimo de 95% no esforço computacional. O processamento de pixel foi, em média, de 1 hora e 20 minutos; já na abordagem com imagens-objeto, este foi reduzido para uma média de 3 minutos. Em relação à detecção automática, a probabilidade de um *breakpoint* associado a um objeto de desmatamento foi inversamente

proporcional ao valor da sua magnitude. A validação dos desmatamentos detectados pelo BFAST Monitor resultou em uma baixa acurácia do produtor para as séries temporais construídas apenas com imagens TM. A inserção de imagens RapidEye resultou em um aumento de 38% na detecção automática dos desmatamentos. Além disso, a média correspondeu ao melhor parâmetro estatístico para a detecção desmatamentos de pequena escala, devido à sua menor influência do erro de comissão. Os resultados evidenciaram que imagens de alta resolução espacial foram fundamentais para o monitoramento de áreas com um padrão altamente fragmentado. Diante disso, pode-se afirmar que a metodologia proposta tem um potencial promissor para as análises de densas séries temporais.

Palavras-chave: Detecção de Mudança. Multi-Sensor. RapidEye. Séries Temporais. BFAST Monitor.

## ABSTRACT

Deforestation of tropical forests represents one of the main anthropic threats to maintaining the stability of these ecosystems. Therefore, the monitoring of these areas is essential to track changes in these environments. In this context, time series are important information for understanding forest ecosystems dynamics. However, the methodologies are mainly based at the pixel level and use images from the same sensor. The aim of this study was to propose a new methodology using multi-sensor time series based on the object, to reduce the computational time and improve the accuracy of automatic detection of small clearings, applying the BFAST Monitor algorithm. The study was developed in an area of the Atlantic Forest in the state of Santa Catarina, in southern Brazil. Due to the high spectral similarity, deforestations were characterized as the removal of forest cover of native or planted vegetation. 230 TM images were acquired (path / row 227/068), between 1984-2011, and 20 RapidEye images (tile 2226122) from 2009-2011. From a multivariate segmentation the study area was delimited into 1972 objects. The values from the average and minimum NDVI of all objects in all images of both sensors were then extracted. This database is the reference for the construction of TM and RapidEye object-images. In this approach, the value of each pixel corresponds to the statistical parameter value assigned to each object. With this methodology, the database was reduced by 97%. Subsequently, these images were used to construct the eight time series assessed in BFAST Monitor. The historical period was defined initially only with the TM images between 1984-2010. Then this period came to consist of TM images from 1984-2008 and RapidEye from 2009-2010. The monitoring period (2011) was set as being composed of TM and RapidEye images separately. The comparison of the average time for the time series processing at the pixel level in relation to the object-based approach, showed a decrease of 95% in the computational effort. The pixel-level processing was, on average, 1 h and 20 min. The object-image approach presented a reduction down to an average of 3 minutes. Regarding automatic detection, the probability of a breakpoint associated to a deforestation object was inversely proportional to the value of its magnitude. The validation of deforestation detected by BFAST Monitor resulted in a low producer's accuracy for the time series constructed only with TM images. The inclusion of RapidEye images resulted in an increase of almost 38% in the automatic detection of deforestation. Furthermore, the average corresponded the best statistical parameter for the detection of small-scale deforestation due to its lesser influence of commission errors. The results showed that high-spatial resolution images were critical for the monitoring of areas with a highly fragmented

pattern. Thus, it can be said that the proposed methodology has promising potential for the analysis of dense time series.

Keywords: Change Detection. Multi-Sensor. RapidEye. Time Series. BFAST Monitor.

## 1 INTRODUÇÃO

O desmatamento de florestas tropicais é uma ameaça antrópica que tem afetado a estabilidade destes ecossistemas, representando uma das principais causas das mudanças ambientais globais (GEIST; LAMBIN, 2002). Considerando a extensão florestal mundial, as florestas tropicais corresponderam aos domínios que sofreram a maior perda de vegetação na última década (HANSEN et al., 2013). Diante disso, o monitoramento a longo do tempo é fundamental para compreender a dinâmica nestas regiões, fornecendo informações sobre aspectos referentes às taxas, aos tipos de mudança e aos padrões espaciais que têm interferido neste processo (LOVELAND; DEFRIES, 2004).

A detecção de mudança pode ser definida como o processo de identificar alterações das feições na superfície terrestre, por meio da comparação da sua condição em diferentes períodos no tempo (SINGH, 1989). Neste caso, técnicas de sensoriamento remoto correspondem a um importante subsídio para tal finalidade, devido às vantagens associadas ao seu custo-benefício, o qual permite o monitoramento das feições na superfície terrestre em diferentes escalas geográficas e com uma frequência regular de aquisição de dados (LUNETTA et al., 2004; ROGAN; CHEN, 2004).

Após a abertura do arquivo Landsat (WOODCOCK, 2008), houve um crescente desenvolvimento na comunidade científica de metodologias multitemporais para acompanhar a dinâmica da cobertura da terra (LU; LI; MORAN, 2014). Neste contexto, o uso de séries temporais representa uma nova alternativa para melhorar a acurácia dos monitoramentos da vegetação. A análise de suas trajetórias ao longo do tempo permite distinguir as respostas espectrais entre alterações fenológicas (dinâmica natural da vegetação), abruptas (desmatamentos, inundações, incêndios) e graduais (degradação da vegetação),

aprimorando a qualidade dos resultados obtidos (VERBESSELT, 2010a, 2010b). Nesta perspectiva, este trabalho foi desenvolvido considerando três aspectos relevantes para o monitoramento da vegetação de ecossistemas tropicais, utilizando a trajetória temporal como alvo de análise.

Primeiro, apesar do avanço na literatura de metodologias com a temática temporal, esta abordagem tem sido direcionada, principalmente, para o monitoramento de florestas temperadas (BROOKS et al., 2013; HUANG et al., 2010; KENNEDY; YANG; COHEN, 2010; ZHU; WOODCOCK, 2014; ZHU; WOODCOCK; OLOFSSON, 2012). Diante disso, este trabalho fundamentou-se no algoritmo BFAST Monitor, proposto por Verbesselt, Zeileis e Herold (2012), uma vez que ele já foi avaliado para o monitoramento de florestas tropicais na Etiópia (DEVRIES et al., 2015) e na Bolívia (DUTRIEUX et al., 2015). No Brasil, já foi aplicado para o monitoramento da Floresta Amazônica (HAMUNYELA; VERBESSELT; HEROLD, 2016; STEPHAN, 2015), no entanto, o conhecimento da dinâmica temporal para outras formações florestais no território nacional ainda é inexistente. Dessa maneira, neste estudo foi investigada a ocorrência de desmatamentos na Mata Atlântica, um *hotspot* mundial de biodiversidade (MYERS et al., 2000). Este bioma representa um desafio para análises de detecção de mudança, uma vez que, devido à grande heterogeneidade da paisagem decorrente da intensa interferência antrópica, a vegetação apresenta um padrão altamente fragmentado (RIBEIRO et al., 2009).

Segundo, os estudos de detecção de mudanças com séries temporais utilizam, principalmente, uma abordagem de pixel (FANG et al., 2014; FRAGAL et al., 2016; JACQUIN; SHEEREN; LACOMBE, 2010; JIN et al., 2013; SULLA-MENASHE et al., 2014; ZHAO; HUANG; ZHU, 2015). Neste caso, deve-se ressaltar que houve um maior desenvolvimento da área computacional, devido às exigências para o processamento destes grandes volumes de informação (COHEN; GOWARD, 2004; HANSEN; LOVELAND,

2012). No entanto, ainda assim, o tempo despendido para o processamento pode ser muito expressivo, principalmente para áreas de ampla extensão territorial e/ou com um denso banco de dados disponível. Portanto, no intuito de reduzir o tempo computacional, neste estudo foi proposta a construção de uma série temporal constituída por imagens-objeto, a qual será descrita detalhadamente na metodologia.

Terceiro, o monitoramento multitemporal da superfície terrestre é realizado, principalmente, com imagens provenientes de um mesmo sensor e, geralmente, eles são de baixa ou média resolução espacial (HUANG; FRIEDL, 2014; KENNEDY et al., 2012; MELLO et al., 2013; SULLA-MENASHE et al., 2014). No entanto, a atual disponibilização de imagens de alta resolução espacial tem permitido a elaboração de novos delineamentos metodológicos para melhorar a precisão dos monitoramentos das mudanças na cobertura da terra (TEWES et al., 2015). Diante disso, neste estudo é proposta uma combinação entre imagens TM (30 m) e RapidEye (5 m), para a construção de uma série temporal multissensor. A integração destes bancos de dados foi realizada no intuito de utilizar o denso arquivo Landsat para obter um padrão robusto da dinâmica da vegetação ao longo dos últimos 30 anos e utilizá-lo como referência para a detecção de pequenos desmatamentos em imagens de alta resolução espacial.

Neste contexto, este trabalho foi realizado no intuito de fornecer uma ferramenta metodológica para auxiliar na tomada de decisão para a gestão pública e ambiental dos ecossistemas tropicais, com grande interferência antrópica. Sendo assim, o objetivo, neste trabalho, foi propor uma nova metodologia utilizando séries temporais multissensor baseadas em objeto para reduzir o tempo computacional e melhorar a precisão da detecção automática de pequenos desmatamentos, aplicando o algoritmo BFAST Monitor. Diante disso, o trabalho foi desenvolvido a fim de responder às seguintes questões científicas:

1. Como uma abordagem baseada em objeto pode aprimorar a análise de séries temporais utilizando sensores de alta (RapidEye) e média (TM) resolução espacial? 2. Como a inserção de imagens de alta resolução espacial (RapidEye) influencia a detecção de pequenos desmatamentos na Mata Atlântica, aplicando o algoritmo BFAST Monitor? 3. Como parâmetros estatísticos influenciam a capacidade de detecção de mudanças na cobertura florestal, aplicando o algoritmo BFAST Monitor?

## 2 MATERIAL E MÉTODOS

Este tópico inicia-se com uma caracterização da área de estudo (seção 2.1). As seções 2.2 e 2.3 incluem as etapas de aquisição e pré-processamento das imagens TM e RapidEye. Em seguida, na seção 2.4 é feita uma descrição detalhada da metodologia proposta para a elaboração das imagens-objeto e construção das séries temporais multissensor. Posteriormente, o algoritmo BFAST Monitor é apresentado na seção 2.6. Nesta seção são apresentadas as etapas para a elaboração do modelo de tendência-sazonalidade, assim como a delimitação dos períodos histórico e de monitoramento para o banco de dados TM e RapidEye. Além disso, a seção inclui uma descrição para os parâmetros de *breakpoint* e magnitude, ambos relevantes para a identificação dos desmatamentos. Por último, na seção 2.6 são apresentados os métodos para avaliar a eficiência das imagens-objeto e a acurácia dos desmatamentos detectados.

### 2.1 Área de estudo

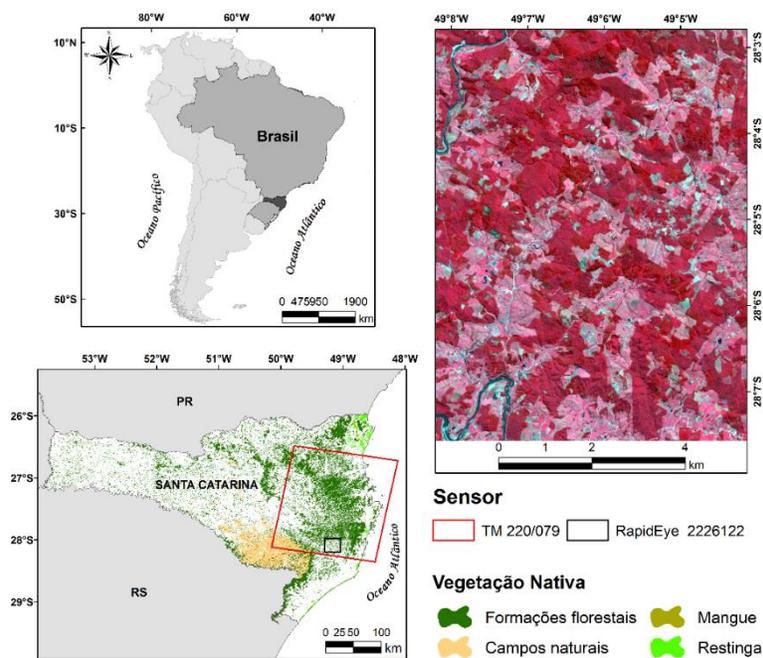
A área de estudo está localizada no estado de Santa Catarina, região sul do Brasil (Figura 3). A área avaliada está inserida no *tile RapidEye* 2226122 (49°6'2" O; 28° 5'11" S), localizada entre os municípios de Santa Rosa de Lima (49°10'56" O; 28°0'42" S) e Rio Fortuna (49° 11' 26"O; 28° 5'35" S), compreendendo 6.246 ha. A região situa-se na porção leste do território catarinense, inserida no Bioma Mata Atlântica, a qual tem histórico antigo de ocupação humana e, devido ao intenso uso antrópico ao longo dos últimos cinco séculos, é representada, em sua maioria, por pequenos fragmentos florestais, inseridos em uma matriz antrópica (RIBEIRO et al., 2009).

Na região avaliada, o tipo de vegetação nativa predominante é a Floresta Ombrófila Densa (BRASIL, 2009), a qual é caracterizada por temperaturas elevadas (média de 25 ° C) e por alta precipitação, bem distribuída ao longo do

ano (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2012). Esta fitofisionomia já teve grande representatividade no estado, com cobertura original estimada em cerca de 31% (KLEIN, 1978). No entanto, atualmente, essa vegetação foi reduzida para cerca de 40% da sua cobertura original no território catarinense (VIBRANS et al., 2013).

Na área de estudo, a paisagem é constituída por remanescentes de vegetação nativa inseridos em uma matriz de áreas agrícolas, manejo florestal e desmatamentos. Além disso, há destaque para o setor madeireiro e, devido à grande heterogeneidade da área e da alta similaridade espectral entre áreas de vegetação nativa e floresta plantada, as mudanças de interesse deste trabalho correspondem à remoção da cobertura florestal (desmatamento), independente da condição inicial da vegetação (natural ou plantada).

Figura 3 - Localização da área de estudo, na região sul do estado de Santa Catarina. Em detalhe, o subset da área avaliada para a imagem RapidEye de 22/09/2011, na composição RGB 5-3-2.



## 2.2 Aquisição e pré-processamento das imagens TM e *RapidEye*

A partir do portal *EarthExplorer* / USGS (<http://earthexplorer.usgs.gov>), foram adquiridas todas as imagens do satélite Landsat 5/TM, órbita/ponto 220/079, disponíveis entre 1984 e 2011, com uma cobertura de nuvem inferior a 30%. Estes dados são coletados em uma frequência de revisita de 16 dias, com resolução espacial de 30 m para as bandas na região do visível e infravermelho do espectro eletromagnético e de 60 m para a banda termal.

Foi utilizado o produto Landsat CDR – *Surface Reflectance Climate Data Record*, o qual é gerado a partir do processamento pelo *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS) (MASEK et al., 2006). Neste caso, as imagens resultantes têm correção geométrica, radiométrica e atmosférica e o sistema de projeção *Universal Transversa de Mercator* (UTM). Este banco de dados resultou em uma série temporal de 230 imagens, com média de 8 imagens/ano (Tabela 1).

As imagens *RapidEye* foram disponibilizadas pela *BlackBridge*, com nível de processamento 3A (correção radiométrica e geométrica) e sistema de projeção UTM. Foram utilizadas todas as imagens *RapidEye* referentes ao *tile* 2226122, disponíveis entre o período de 2009 e 2011. O período de início da aquisição de dados (2009) é limitado pelo lançamento da constelação de satélites *RapidEye*, em 2008. Esta restrição resultou em uma série temporal composta por 20 imagens. Neste caso, há uma distribuição semelhante no número de imagens ao longo dos três anos, com seis imagens para 2009 e 2011 e oito imagens para 2010.

Para obter os valores de reflectância no nível do solo, foi realizada a correção atmosférica de todas as imagens *RapidEye*, utilizando o algoritmo *Quick Atmospheric Correction*, QUAC. Este método corrige a influência de fatores atmosféricos para regiões do visível e do infravermelho, entre a extensão

de 400 a 2.500 nm, do espectro eletromagnético (QUAC..., 2009). Para a correção, o algoritmo requer o comprimento de onda central de cada banda, o qual foi configurado para a banda do azul como 475 nm; verde, 555 nm; vermelho, 657,5 nm; *red-edge*, 710 nm e infravermelho-próximo, 805 nm.

Os parâmetros para eliminar a influência dos efeitos atmosféricos são extraídos diretamente dos pixels observados na imagem, baseando-se na observação empírica da reflectância de diferentes alvos espectrais, não sendo necessário, portanto, fornecer informações de metadados. Posteriormente, para identificar os pixels cobertos por nuvens ou sombras, foi feita uma análise visual de todas as imagens. Neste caso, para cada imagem *RapidEye* da série temporal foi elaborada, manualmente, uma máscara de nuvem e sombra, para a remoção destes pixels nas análises subsequentes.

Tabela 1 - Distribuição das imagens ao longo da série temporal TM de 28 anos (1984-2011).

<b>Ano</b>	<b>Imagens</b>	<b>Ano</b>	<b>Imagens</b>
1984	2	1998	6
1985	4	1999	9
1986	9	2000	12
1987	10	2001	10
1988	12	2002	3
1989	0	2003	5
1990	8	2004	13
1991	7	2005	14
1992	7	2006	15
1993	11	2007	9
1994	7	2008	8
1995	4	2009	10
1996	8	2010	10
1997	10	2011	7

Para finalizar o pré-processamento, foi calculado o NDVI para todas as imagens TM e *RapidEye*, sendo removidos todos os pixels cobertos por nuvens ou sombra. Neste caso, nas imagens TM foram aplicadas as máscaras

disponíveis no produto CDR, enquanto, nas imagens RapidEye, foram utilizadas as máscaras elaboradas manualmente. As etapas de pré-processamento foram automatizadas a partir da elaboração de rotinas para o *software* R 3.1.3 e para a extensão *Model Builder* do ArcGIS 10.3.

### **2.3 Máscara de vegetação aplicada a 2011**

Para direcionar as análises para as mudanças de interesse, foi elaborada uma máscara no intuito de manter somente as áreas de vegetação, com cobertura florestal superior a 70%. Neste trabalho, o desmatamento é caracterizado como a remoção da cobertura florestal ocorrida na vegetação nativa ou plantada. Esta abordagem foi considerada por causa da grande incidência de florestas plantadas entremeadas à vegetação natural na área analisada, o que dificultou a distinção destas classes no mapeamento devido à grande similaridade espectral e textural destes alvos.

A máscara para remover as áreas não florestais foi obtida a partir de uma classificação baseada em objeto da imagem RapidEye adquirida em 04/02/2011, utilizando o algoritmo vizinho mais próximo. Posteriormente, foi aplicada em todas as imagens NDVI dos sensores TM e RapidEye. Este processamento resultou nas séries temporais de pixel NDVI/TM<sub>8411</sub> (imagens TM entre 1984-2011) e NDVI/RapidEye<sub>0911</sub> (imagens RapidEye entre 2009-2011), com máscara de nuvem e vegetação aplicadas.

### **2.4 Séries temporais baseadas em objeto**

#### **2.4.1 Construção das imagens-objeto**

A análise das séries temporais foi realizada em objetos, os quais são criados a partir do agrupamento de pixels de acordo com suas características

geográfica, espectral e espacial. Esta abordagem foi utilizada a fim de reduzir o tempo computacional despendido para o processamento de séries temporais. Além disso, a abordagem baseada em objeto auxilia na caracterização dos elementos da paisagem, facilitando a interpretação dos resultados (BLASCHKE, 2010). Diante disso, neste trabalho propõe-se a construção de imagens-objeto (Figura 4). O código-fonte deste método foi escrito em linguagem *Interactive Data Language*, IDL.

O número total de objetos ( $N$ ) obtidos a partir da segmentação das imagens multiespectrais é utilizado como parâmetro para a criação de uma matriz quadrada ( $A$ ). A imagem-objeto (IO) é obtida por meio da inserção dos parâmetros estatísticos nesta matriz, na qual a localização de cada célula ( $A_{i,j}$ ) corresponde ao valor do objeto  $n$  na data  $x$ . Essa abordagem reduz o número de pixels e, conseqüentemente, o volume de dados que será processado.

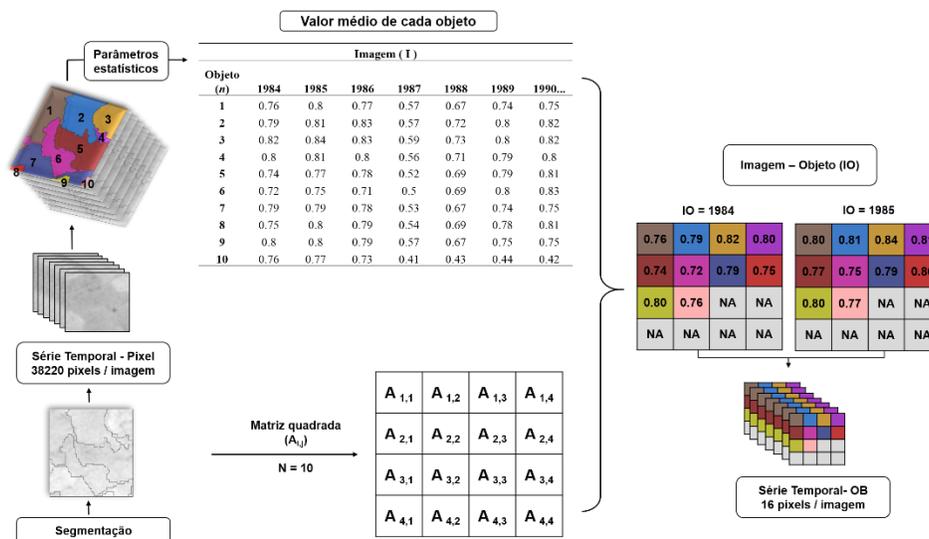
Na Figura 4 estão ilustradas as etapas da construção de uma série temporal baseada em objeto (*object-based*, OB), com imagens-objeto. O número total de objetos ( $N = 10$ ) obtido a partir da segmentação é utilizado como parâmetro para a criação de uma matriz quadrada, a qual, neste exemplo, resultou na configuração de  $4 \times 4$  pixels. Como uma matriz quadrada deve ter o mesmo número de linhas e colunas, valores NoData (NA) são adicionados aos 6 pixels acrescentados à matriz, a fim de manter esta proporção.

Em cada imagem-objeto resultante, o valor de cada pixel é correspondente ao valor médio extraído de cada objeto, de acordo com cada imagem ( $I$ ). Por exemplo, considerando os valores médios extraídos para os objetos na primeira imagem ( $I_{1984}$ ), a imagem-objeto ( $IO_{1984}$ ) equivalente é obtida da seguinte maneira: a célula  $A_{1 \times 1}$  corresponde ao valor médio do objeto 1, na imagem  $I = 1984$ . Da mesma forma, a célula  $A_{1 \times 2}$  corresponde ao valor médio do objeto 2, na imagem  $I = 1984$  e, assim, sucessivamente para os 10 objetos. Essa metodologia reduz o número de pixels e, conseqüentemente, o

volume de dados que será processado. No exemplo ilustrado, uma imagem com 38.220 pixels foi reduzida para uma imagem-objeto equivalente, com 16 pixels.

Além disso, é importante mencionar que, como o número de linhas e colunas é constante na matriz quadrada (utilizando uma mesma segmentação como referência), a construção dessas imagens também permite a combinação de dados multissensor, com a vantagem da manutenção de suas resoluções espaciais.

Figura 4 - Representação esquemática da metodologia para construção das imagens baseadas em objeto. O código-fonte foi escrito na linguagem IDL.



#### 2.4.2 Construção das séries temporais com imagens-objeto TM e RapidEye

Neste estudo, para a delimitação dos objetos, foi utilizada a segmentação multidata, proposta inicialmente por Desclée, Bogaert e Defourny (2006). Devido à melhor resolução espacial, a segmentação foi realizada utilizando-se as imagens RapidEye referentes ao primeiro (04/02/2011) e ao último (22/09/2011)

registro de 2011 deste sensor. Em princípio, foi aplicada a máscara de vegetação, a fim de direcionar as análises apenas para as áreas correspondentes a cobertura florestal na condição inicial. A fim de obter objetos condizentes com suas características espectro-temporais, o algoritmo *multi-resolution image segmentation* foi aplicado, atribuindo pesos iguais para as bandas 1 a 5, de ambas as datas. Neste caso, os objetos são delimitados considerando a forma, a variação espectral e a localização geográfica entre a sua condição inicial e final. Os parâmetros do algoritmo foram configurados com um fator de escala 80, forma 0,3 e compacidade 0,6. Este processo resultou em 1.972 objetos de vegetação. Este processamento foi realizado utilizando-se o software *eCognition Developer 9*.

Em seguida, esta segmentação foi sobreposta às séries temporais em nível de pixel NDVI/TM<sub>8411</sub> e NDVI/RapidEye<sub>0911</sub>, sendo extraídos os valores médios e mínimos de cada objeto, em todas as datas, para ambos os sensores. Como o desmatamento é caracterizado por uma redução no valor de NDVI, estes parâmetros foram escolhidos a fim de obter uma caracterização representativa da trajetória temporal dos objetos de desmatamento.

O uso da mesma segmentação para extrair os parâmetros estatísticos dos objetos nas séries temporais NDVI/TM<sub>8411</sub> e NDVI/RapidEye<sub>0911</sub> manteve constante o número de linhas e colunas da matriz de referência TM e RapidEye. Esta condição permitiu uma combinação das imagens de ambos os sensores, sem a necessidade de alterar a resolução espacial para que houvesse uma correspondência entre os pixels das imagens TM e RapidEye.

Como uma matriz quadrada deve apresentar o mesmo número de linhas e colunas, o total de 1.972 objetos de vegetação extraídos pela segmentação resultou na configuração de uma matriz de 45 x 45 pixels. Nesta matriz, 53 células foram configuradas como *NoData* (NA) para manter a mesma proporção entre linhas e colunas. Esta matriz foi a referência para a criação das imagens-objeto. Para isso, foi feita uma relação entre as matrizes e os valores dos objetos

extraídos para as séries temporais em nível de pixel NDVI/TM<sub>8411</sub> e NDVI/RapidEye<sub>0911</sub>.

Neste caso, o valor das células em cada matriz foi configurado como sendo correspondente ao valor do parâmetro estatístico (média ou mínimo) de cada objeto, para cada data. Por exemplo, considerando os valores médios extraídos para os objetos na primeira imagem ( $I_1$ ) da série temporal NDVI/TM<sub>8411</sub>, a imagem-objeto ( $IO_1$ ) equivalente é obtida da seguinte maneira: a célula  $A_{1 \times 1}$  corresponde ao valor médio do objeto 1, na imagem  $I_1$ . Da mesma forma, a célula  $A_{1 \times 2}$  corresponde ao valor médio do objeto 2, na imagem  $I_1$ , e assim, sucessivamente, para os 1.972 objetos. Esta condição resultou em um conjunto de imagens-objeto em que o valor de cada pixel corresponde ao valor médio de NDVI para um determinado objeto. Este processo foi replicado para todas as imagens NDVI/TM<sub>8411</sub> e NDVI/<sub>0911</sub>, a fim de extrair os valores médios e mínimos para cada objeto. Em seguida, estas imagens-objeto foram utilizadas para a construção das séries temporais analisadas pelo algoritmo BFAST Monitor.

## 2.5 BFAST Monitor

O método BFAST Monitor (*Breaks For Additive Season and Trend Monitor*), proposto por Verbesselt, Zeileis e Herold (2012), foi a referência para a detecção de mudanças na vegetação neste estudo. Esta metodologia está disponível no pacote *bfastSpatial* (DUTRIEUX; DEVRIES; VERBESSELT, 2014), implementado no R (R CORE TEAM, 2015), um *software* de livre acesso. Este algoritmo possibilita a análise não apenas para pixels individuais, mas também para séries temporais de extensos arquivos matriciais. Para este trabalho, o código-fonte foi adaptado para a análise das séries temporais construídas com imagens-objeto (Figura 5). Os parâmetros configurados neste trabalho para análise do algoritmo estão descritos na Tabela 2.

Figura 5 - Fluxograma das três etapas de análise do BFAST Monitor para a detecção de desmatamentos nas séries temporais com imagens-objeto.

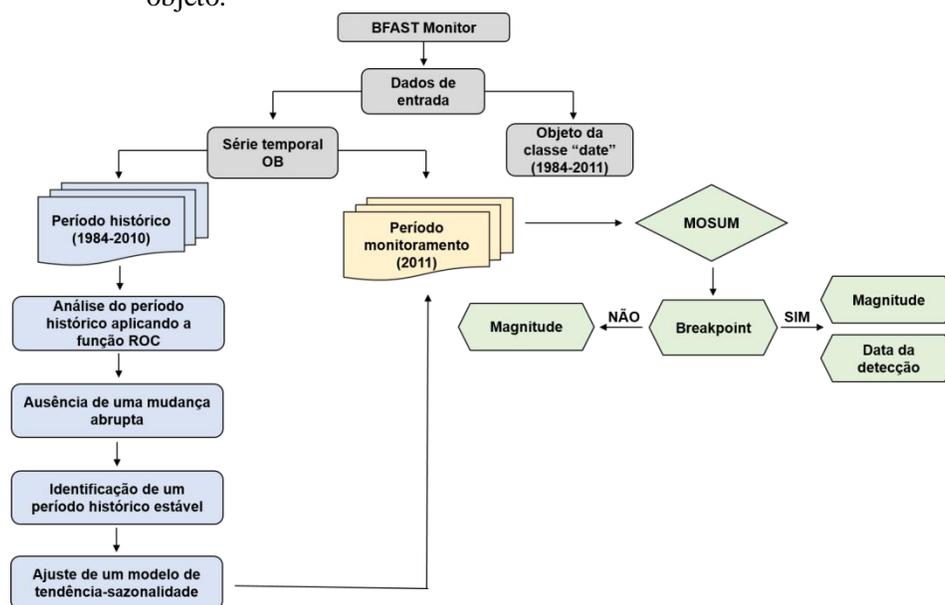


Tabela 2 - Parâmetros configurados para a análise das séries temporais pelo BFAST Monitor, em que OB = object-based; ROC = Reversed Ordered Cumulative; MOSUM = Soma Móvel.

Parâmetros	Configuração	Descrição
<b>x</b>	Série Temporal OB	Arquivo raster
<b>dates</b>	vetor com as datas (1984 até 2011)	Objeto da classe <i>date</i>
<b>start</b>	c (2011,1)	Início do período de monitoramento
<b>formula</b>	response ~ trend + harmon	Modelo de regressão
<b>order</b>	1	Ordem do termo harmônico
<b>history</b>	ROC	Período histórico estável
<b>type</b>	MOSUM	Tipo do processo de monitoramento
<b>h</b>	0.25	Tamanho da janela MOSUM

### 2.5.1 Ajuste do modelo de tendência e sazonalidade

A partir de toda a série temporal, o banco de dados de cada pixel ao longo do tempo é dividido em: (a) um período histórico, que corresponde ao conjunto de dados de referência e (b) um período de monitoramento, no qual a ocorrência de mudanças será avaliada. Neste trabalho, estes foram definidos como 1984-2010 e 2011, respectivamente.

Para que o ajuste do modelo de tendência-sazonalidade seja representativo da dinâmica da vegetação, é necessária uma ausência de distúrbios nas observações inseridas no período histórico. Entretanto, seria um equívoco assumir esta premissa para todas as observações compreendidas no intervalo de 1984 a 2010. Neste caso, o método *Reversed-ordered-cumulative - ROC* (PESARAN; TIMMERMANN, 2002) é aplicado para identificar um período histórico estável (*subset* do período histórico) para cada observação. Este *subset* é a referência para obter o ajuste do modelo de regressão, o qual corresponde ao parâmetro de comparação para análise do período de monitoramento.

Um modelo de tendência-sazonalidade foi ajustado para cada objeto independentemente. A equação (1) demonstra o modelo de tendência-sazonalidade formulado como uma regressão logística ordinal, composto por uma tendência linear e uma componente sazonal harmônica, o qual é ajustado para as observações do período histórico:

$$y_t = \alpha_1 + \alpha_2 t + \sum_{j=1}^k \gamma_j \sin\left(\frac{2\pi j t}{f} + \delta_j\right) + \varepsilon_t, \quad (1)$$

em que, para cada pixel observado ( $y_t$ ) no tempo  $t$ , são definidas: (a) uma componente sazonal harmônica definida pela amplitude  $\gamma$ , fase  $\delta$  e frequência

temporal  $f$  das observações e (b) uma componente de tendência, definida pelo intercepto  $\alpha_1$ , inclinação e  $\alpha_2$ . A componente residual dos dados é representada por  $\varepsilon_t$ . De acordo com os resultados obtidos por Dutriex et al. (2015), a componente harmônica foi configurada para uma ordem igual a 1.

### 2.5.2 Detecção de breakpoints no período de monitoramento

Dada uma trajetória temporal da vegetação, alterações do seu comportamento padrão podem indicar uma mudança na cobertura da terra, a qual é identificada pelo BFAST Monitor como um *breakpoint*. Para a detecção de *breakpoints*, a estabilidade do modelo de tendência-sazonalidade estimado no período histórico é testada para as novas observações, representadas pelo período de monitoramento. Neste caso, a identificação de *breakpoints* é determinada pela ocorrência de um desvio significativo entre os valores observados no período de monitoramento em relação aos valores ajustados pelo modelo de tendência-sazonalidade. A estimativa é feita utilizando-se uma janela de soma móvel (MOSUM), a qual considera todas as observações do período de monitoramento, sendo ser expressa por

$$MO_t = \frac{1}{\hat{\sigma}\sqrt{n}} \sum_{s=t-h+1}^t (y_s - \hat{y}_s) \quad (2)$$

em que  $\hat{\sigma}$  corresponde ao estimador da variância. Os parâmetros  $y_s$  e  $\hat{y}_s$  são os valores observados e esperados, respectivamente. A largura da janela MOSUM é definida por  $h$ , o qual pode variar entre zero e um, sendo correspondente a uma fração do número de observações no período histórico ( $n$ ), por exemplo,  $h = n/4$ . Neste estudo, o parâmetro  $h$  foi configurado como 0,25. A hipótese de

estabilidade estrutural é rejeitada quando MOSUM desvia de zero com um nível de significância de 95%, o que determina a ocorrência de um *breakpoint*.

### 2.5.3 Intervalo da magnitude para o período de monitoramento

A magnitude é calculada considerando-se todos os valores observados e esperados, enquanto um *breakpoint* é resultante do desvio significativo entre estes valores. Isso significa que a magnitude é calculada para todos os objetos, independentemente da ocorrência de um *breakpoint*. Como demonstrado na equação (3), a magnitude ( $M$ ) é computada a partir da mediana dos resíduos, obtida pela diferença entre  $y_t$  (valores observados) e  $\hat{y}_t$  (valores preditos) dentro do período de monitoramento.

$$M = \text{median}\{y_t - \hat{y}_t\} \quad (3)$$

Dessa maneira, a magnitude pode auxiliar na caracterização e na distinção dos desmatamentos ao longo da série temporal. Este parâmetro é importante porque *breakpoints* também podem ser decorrentes de alterações na cobertura da Terra decorrentes de acentuadas variações sazonais na cobertura florestal, as quais não estão relacionadas à nossa mudança de interesse. Diante disso, utilizar o critério da ocorrência de um *breakpoint* como o único parâmetro de análise pode determinar a influência de um alto erro de comissão.

Portanto, para avaliar como este parâmetro pode auxiliar na detecção de desmatamentos, as análises posteriores aos resultados do BFAST Monitor foram realizadas considerando-se todos os *breakpoints* detectados, assim como considerando dois limites para os valores de magnitude. Neste caso, foram avaliados somente os *breakpoints* com uma magnitude  $< -0,0001$  e uma magnitude  $< 0,1$ .

Além disso, a magnitude da mudança pode ser influenciada pelo comprimento do período de monitoramento, uma vez que o aumento no número de observações antes e após o evento de mudança pode afetar os valores obtidos por esta medida (DEVRIES et al., 2015). Por isso, o período de monitoramento deste estudo foi limitado para as mudanças ocorridas no intervalo de um ano (2011). Esta restrição pode garantir que eventos que influenciem a dinâmica pós-mudança tenham um pequeno efeito nos valores obtidos para este parâmetro.

#### **2.5.4 Detecção de desmatamento com séries temporais multissensor baseadas em objeto**

A metodologia aplicada neste trabalho para análise das séries temporais baseadas em objeto pelo BFAST monitor está detalhada em um fluxograma, na Figura 6. Estas séries temporais foram construídas no intuito de avaliar como a inserção de imagens de alta resolução espacial influencia a capacidade de detecção de desmatamentos pelo algoritmo. Para isso, as imagens-objeto NDVI/RapidEye foram inseridas no período histórico e/ou no período de monitoramento, sendo a influência nos resultados comparada com as séries temporais constituídas por imagens-objeto NDVI/TM.

Para facilitar o entendimento dos parâmetros das oito séries temporais construídas, uma nomenclatura foi padronizada com as informações de suas componentes, na qual o nome de cada série temporal é composto por três elementos: <Nome do sensor utilizado no Período histórico> / <Nome do sensor utilizado no Período de monitoramento>\_<Parâmetro estatístico extraído dos objetos>. O número de imagens utilizado em cada série temporal está descrito na Tabela 3.

Inicialmente, o período histórico foi fixado somente com as imagens-objeto do sensor TM entre 1984-2010. Esta condição resultou nas séries

temporais: (a)  $TM / TM_{mean}$  e  $TM / TM_{min}$ , cujo período histórico e período de monitoramento são constituídos apenas por imagens NDVI/TM; (b)  $TM / RE_{mean}$  e  $TM / RE_{min}$ , em que o período histórico é constituído por imagens NDVI/TM entre 1984-2010 e o período de monitoramento formado apenas pelas imagens NDVI/RapidEye do ano de 2011 (Figura 7).

Em seguida, as imagens-objeto NDVI/TM entre 2009 e 2010 foram substituídas pelas imagens NDVI/RapidEye disponíveis neste período, caracterizando um período histórico multissensor, que foi combinado com o período de monitoramento (2011), formado pelas imagens-objeto NDVI/TM e NDVI/RapidEye, separadamente. Esta condição resultou nas séries temporais: (c)  $TMRE / TM_{mean}$  e  $TMRE / TM_{min}$ , em que o período histórico é constituído por imagens TM entre 1984-2008 e imagens RapidEye entre 2009-2010, enquanto o período de monitoramento é formado apenas por imagens TM; (d)  $TMRE / RE_{mean}$  e  $TMRE / RE_{min}$ , em que as séries temporais são constituídas pelo mesmo período histórico multissensor, mas combinado ao período de monitoramento composto apenas por imagens RapidEye (Figura 8).

Figura 6 - Fluxograma da metodologia para construção das séries temporais baseadas em objeto e utilizadas para análise no BFAST Monitor.

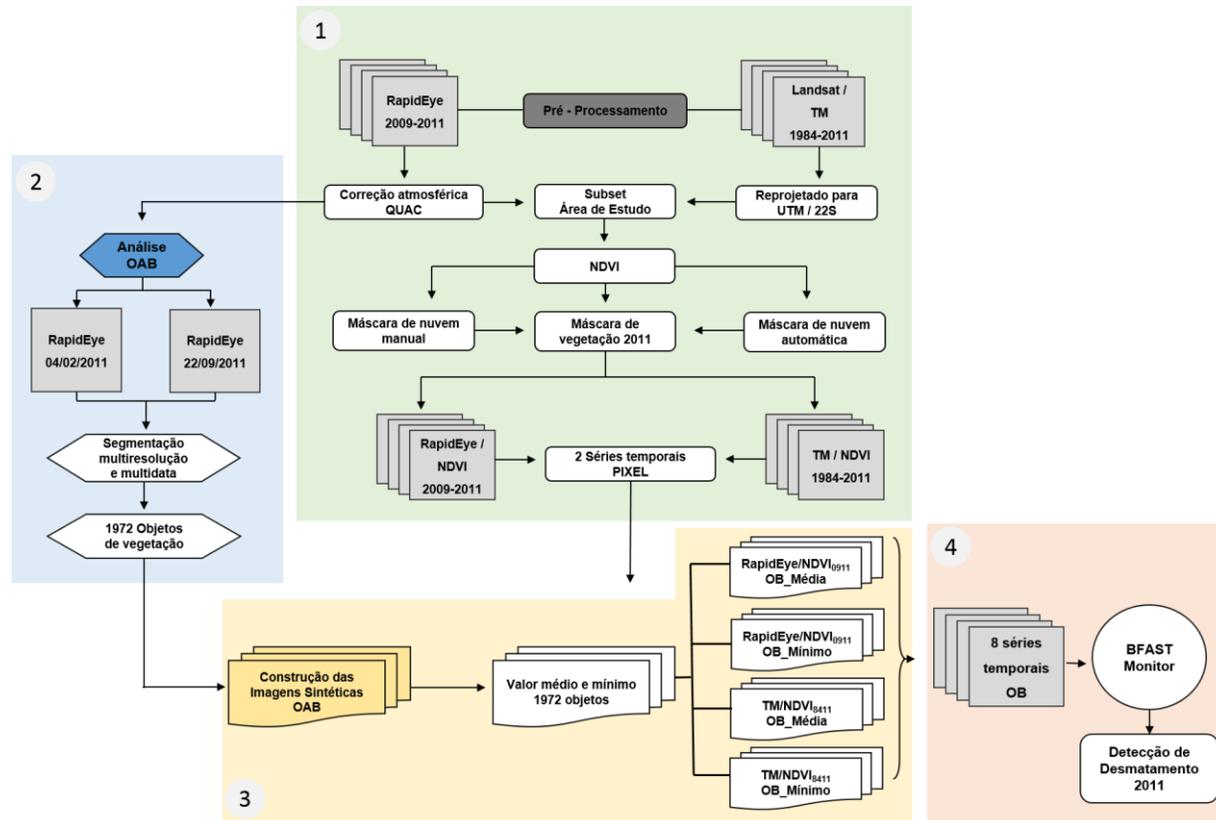


Tabela 3 - Número de imagens TM e RapidEye utilizadas no período histórico e no período de monitoramento, para construção das oito séries temporais baseadas em objeto.

Série Temporal OB	Imagens				
	Período Histórico		Período Monitoramento		Total
	TM	RapidEye	TM	RapidEye	
TM/TM_mean	223	-	7	0	230
TM/TM_min	223	-	7	0	230
TM/RE_mean	223	-	-	6	229
TM/RE_min	223	-	-	6	229
TMRE/TM_mean	187	14	7	-	208
TMRE/TM_min	187	14	7	-	208
TMRE/RE_mean	187	14	-	6	207
TM RE/RE_min	187	14	-	6	207

Figura 7 - Fluxograma para a construção das quatro séries temporais com imagens-objeto, utilizando o período histórico TM.

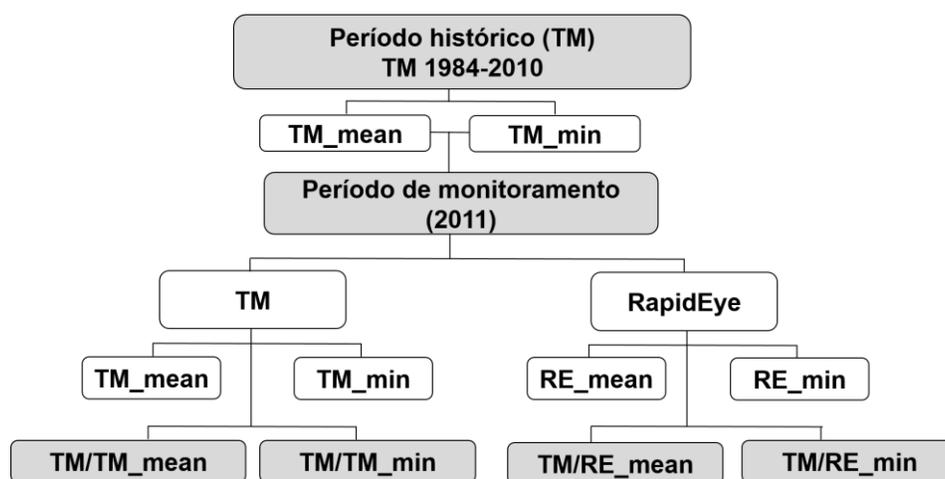
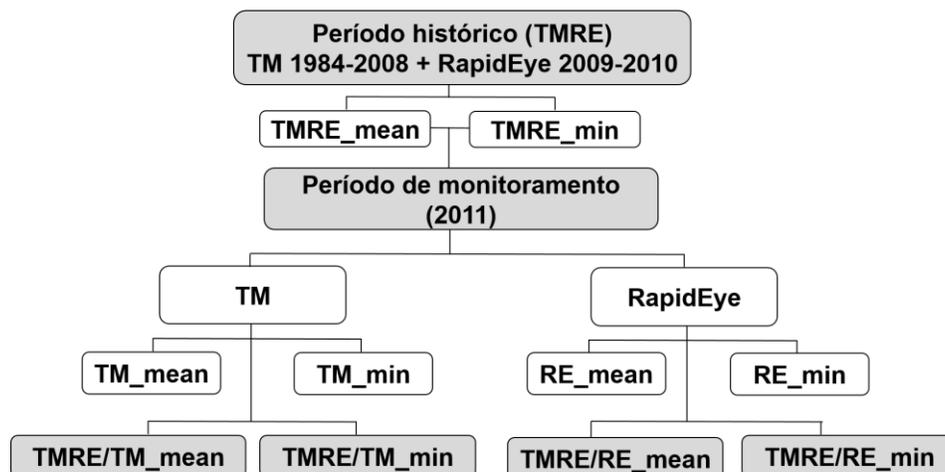


Figura 8 - Fluxograma para construção das quatro séries temporais com imagens-objeto, utilizando o período histórico multissensor TMRE.



## 2.6 Validação dos resultados

### 2.6.1 Tempo computacional: pixel x OB

Para as análises do BFAST Monitor, um modelo de regressão é ajustado independentemente, para cada pixel da imagem. A extensão da área avaliada é equivalente a uma imagem TM com cerca de 69.795 pixels (equivalente a uma imagem RapidEye com 2.498.462 pixels) ou uma imagem-objeto com 2.025 pixels (1.972 objetos de vegetação e 53 objetos *NoData*). Considerando que o processo deve ser replicado para oito séries temporais que contêm entre 207 a 230 imagens cada, a comparação do esforço computacional foi utilizada como parâmetro para avaliar a eficiência das imagens-objeto em relação à abordagem em nível de pixel.

Dessa maneira, foi computado o tempo despendido para o processamento da série temporal em nível de pixel NDVI/TM<sub>8411</sub>, em relação à série temporal baseada em objeto TM/TM\_mean. Ambas as séries temporais têm

a mesma extensão e são constituídas por 230 imagens. No entanto, devido à variação no número de pixels, o processamento foi replicado 16.052.850 vezes para a série NDVI/TM<sub>8411</sub> e 465.750 vezes para TM/TM\_mean.

### **2.6.2 Elaboração do mapa de referência para 2011**

As imagens RapidEye adquiridas em 04/02/2011 e 22/09/2011, assim como a segmentação obtida anteriormente utilizando este banco de dados, foram utilizadas como referência para o mapeamento da cobertura florestal no ano de 2011. As variáveis espectrais média, desvio padrão, brilho e máxima diferença de cada objeto para as cinco bandas de ambas as imagens foram utilizadas como referência para a classificação temática, aplicando o algoritmo vizinho mais próximo. Em seguida, foi feita uma interpretação visual, a fim de melhorar a precisão desta classificação automática. Para garantir uma análise minuciosa, o mapeamento foi dividido em grids de 1 x 1 km e, padronizando uma escala de 1:3350, para avaliar os resultados da classificação automática em cada subset.

Este processo resultou no mapa de cobertura da terra com 1.897 objetos de vegetação (não mudança) e 75 objetos de desmatamento (mudança). O tamanho médio dos objetos de mudança foi de 0,66 ha, variando entre 0,14 e 1,7 ha. Considerando que extensão da área registrada por um pixel TM é de 0,09 ha, o menor objeto de desmatamento identificado pelo intérprete corresponde a cerca de 15 pixels deste sensor, o qual equivale a 56 pixels RapidEye. Essa condição indica que todos os desmatamentos detectados pelo intérprete também podem ser identificados em ambos os sistemas sensores.

Diante disso, o mapa de cobertura da terra obtido foi utilizado como referência para obter as matrizes de confusão para as oito séries temporais baseadas em objeto. Posteriormente, foram calculadas a acurácia do produtor, a acurácia do usuário, o erro de comissão e o erro de omissão de cada série

temporal, considerando todos os *breakpoints* detectados, assim como somente aqueles com magnitude  $<0,1$  e magnitude  $<-0,0001$ .

No intuito de caracterizar os desmatamentos de acordo com a intensidade do distúrbio, foi extraído valor de magnitude dos 75 objetos de desmatamento, independente da ocorrência de um *breakpoint*. Além disso, a fim de avaliar a probabilidade de um objeto de desmatamento detectado pelo intérprete ser também detectado pelo BFAST Monitor, foi feita uma relação percentual entre número de objetos/classe de magnitude detectados pelo intérprete e pelo algoritmo.

### **3 RESULTADOS & DISCUSSÃO**

Os resultados deste trabalho foram sumarizados em cinco tópicos. Inicialmente, na sessão 3.1, foi feita uma discussão sobre a construção das imagens-objeto, a fim de reduzir o tempo de processamento. Posteriormente, uma caracterização das trajetórias temporais da vegetação na área avaliada é demonstrada na sessão 3.2. Em seguida, os resultados são direcionados para uma análise mais específica dos resultados obtidos pelo BFAST Monitor. Na sessão 3.3 é avaliada como a magnitude influenciou nos parâmetros extraídos das matrizes de confusão. Em seguida, na sessão 3.4 discute-se como as imagens RapidEye contribuíram positivamente para a detecção dos desmatamentos. Para finalizar, no tópico 3.5 foram evidenciados os principais fatores que condicionaram a ocorrência de erros nos resultados obtidos.

#### **3.1 Séries temporais multissensor TM/RapidEye baseadas em objeto**

A fim de reduzir o volume de dados para processamento de séries temporais, neste trabalho foi proposta a elaboração de imagens-objeto. Entre as vantagens da conversão das imagens em nível de pixel para imagens-objeto, destacam-se as descritas a seguir.

(i) A redução significativa do tempo computacional despendido para a análise de séries temporais. A comparação do esforço computacional despendido para a análise da série temporal baseada em objeto (TM/TM\_mean), em relação à série temporal em nível de pixel (NDVI/TM<sub>8411</sub>), determinou uma redução de 95% no tempo de processamento do BFAST Monitor. Apesar da possibilidade de particionar o processamento de séries temporais em nível de pixel em múltiplos computadores, esta condição nem sempre é viável devido ao custo e à disponibilidade de equipamentos.

Diante disso, a redução do tempo computacional é um fator relevante no processamento de séries temporais. Neste trabalho, para uma área relativamente pequena, o uso de imagens-objeto reduziu o banco de dados em 97%. Essa condição reduziu o tempo médio de processamento de 1 hora e 20 minutos, para cerca de 3 minutos. Entretanto, para o monitoramento de áreas extensas, o tempo consumido pode ser muito mais expressivo. Em um estudo recente, Dutriex et al. (2016) realizaram uma segmentação temporal utilizando um algoritmo de detecção de *breakpoint*. A análise de 65.000 objetos em uma série temporal com 25 imagens resultou em um tempo médio de 25 horas de processamento. Considerando o aumento no tempo de processamento proporcional ao volume de dados, na comparação com a metodologia de imagens-objeto, presume-se que o tempo de processamento deste banco de dados seria estimado em torno de 12 minutos.

(ii) A possibilidade de utilizar imagens multissensor de forma complementar. Deve-se ressaltar que a metodologia proposta foi avaliada para imagens TM e RapidEye, no entanto, esta abordagem pode ser aplicada para qualquer sensor, independente do atributo avaliado (índices espectrais, valores de radiância ou reflectância). Mesmo com a ausência de um longo contexto histórico, esta metodologia viabilizou o uso das imagens RapidEye, devido à construção das séries temporais utilizando o denso volume de imagens TM como referência, para o monitoramento dos desmatamentos. Além disso, esta abordagem manteve a resolução espacial de ambos os sensores.

Reiche et al. (2015) também desenvolveram uma metodologia multissensor para a análise de séries temporais aplicando o algoritmo BFAST Monitor. O método é adequado para o monitoramento de florestas tropicais, pois consiste na fusão de imagens ópticas com imagens de radar, as quais têm menor influência de fatores atmosféricos. Contudo, esta abordagem ainda pode ser limitada para a análise de imagens de alta resolução espacial, considerando o

volume de informação disponível. Como exemplo, o banco de dados RapidEye teve início em 2009, com uma frequência temporal irregular na aquisição de imagens. Nas análises utilizando o BFAST Monitor para que os resultados sejam precisos, Verbesselt, Zeileis e Herold (2012) sugerem um período histórico estável de, pelo menos, dois anos, considerando uma frequência temporal de 16 dias, o que correspondeu a 46 observações. Dutrieux et al. (2015) também ressaltam que a construção de um comportamento histórico suficientemente longo é fundamental para obter um modelo de regressão preciso para a análise do BFAST Monitor. Diante disso, as imagens TM entre 1984 e 2010 foram fundamentais para uma análise robusta da trajetória temporal das imagens RapidEye em 2011.

Deve-se salientar que os estudos citados anteriormente indicam um avanço para o monitoramento da vegetação, entretanto, ainda existem algumas limitações devido ao tempo computacional e à disponibilidade de dados. Diante disso, a metodologia proposta neste trabalho para a construção de séries temporais multissensor com imagens-objeto pode reduzir significativamente o tempo de processamento e também aprimorar os monitoramentos com o uso de imagens de alta resolução espacial. O arquivo Landsat corresponde à série mais longa de observação da superfície terrestre (HANSEN; LOVELAND, 2012; WULDER et al., 2011), enquanto as imagens provenientes da constelação RapidEye representam uma nova alternativa para melhorar a precisão do monitoramento de ecossistemas florestais (GOMES; MAILLARDA, 2015; POTAPOV et al., 2014; TAPSALL; MILENOV; TASDEMIR, 2010; TIGGES; LAKES; HOSTERT, 2013). Dessa maneira, a combinação das informações de ambos os sensores, integrada a um menor tempo de processamento, corresponde a um importante subsídio para o monitoramento de desmatamentos de pequena escala, em estudos de ampla extensão territorial.

### 3.2 Caracterização da dinâmica florestal na área de estudo

A partir de séries temporais multissensor baseadas em objeto, foi avaliado como a inserção de imagens RapidEye influenciou a capacidade de detecção de pequenos desmatamentos na Mata Atlântica. Um modelo de tendência-sazonalidade foi ajustado a partir do período histórico estável e, posteriormente, o teste MOSUM foi aplicado ao período de monitoramento. A ocorrência de *breakpoints* foi avaliada a partir da relação entre os valores de NDVI observados e ajustados pelo modelo.

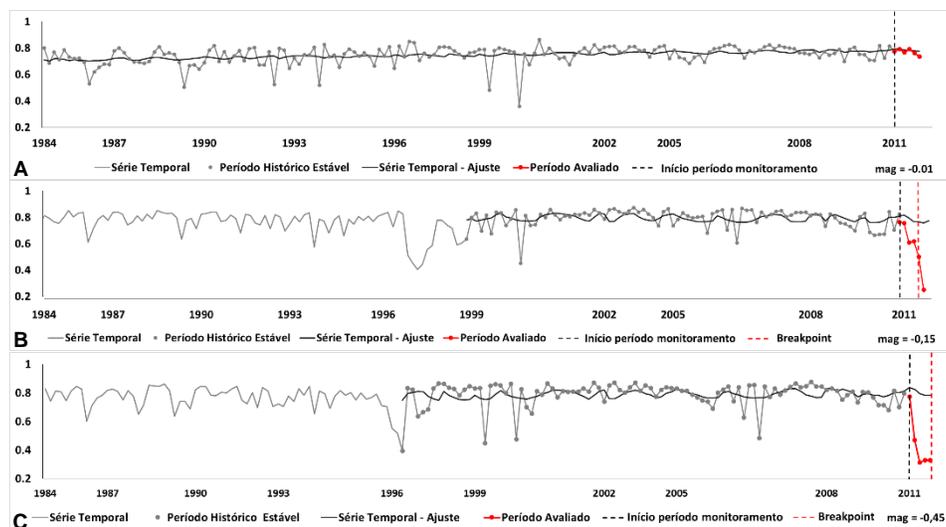
Na Figura 9 mostra-se o resultado do BFAST Monitor para três objetos com diferentes níveis de distúrbios, considerando a série temporal TMRE/RE\_mean. A linha preta pontilhada representa o fim do período histórico (1984-2010) e o início do período de monitoramento (2011). A partir do método ROC, é obtido o período histórico estável (pontos cinzas) de cada objeto, o qual é variável de acordo com a sua trajetória temporal. A linha preta contínua corresponde ao modelo de tendência-sazonalidade ajustado, o qual foi testado para o período de monitoramento (linha contínua com pontos vermelhos). Distúrbios na vegetação são indicados por *breakpoints* (linha vermelha pontilhada).

Foi observado que quanto maior o desvio dos valores de NDVI no período de monitoramento em relação aos valores ajustados, menor o valor da magnitude. No Gráfico 9A está representada a trajetória temporal de um objeto de vegetação com uma dinâmica estável. Este é caracterizado por um período de monitoramento com valores próximo ao modelo ajustado, com magnitude de -0,01. Já para os objetos seguintes, houve um desvio significativo entre os valores observados e preditos, resultando na ocorrência de *breakpoints*.

O desmatamento é caracterizado por uma redução nos valores de NDVI, sendo identificado como um desvio negativo em relação ao modelo de regressão ajustado. O Gráfico 9B corresponde a uma remoção gradativa da vegetação,

correspondendo a um *breakpoint* com magnitude de  $-0,15$ . Já o Gráfico 5C caracteriza um processo abrupto de remoção florestal, no qual o *breakpoint* correspondeu a uma magnitude de  $-0,45$ . Em ambos os gráficos, a quebra ocorreu na quinta observação do período de monitoramento. Além disso, é importante ressaltar que a identificação de um *breakpoint* é um indicativo de um desmatamento, mas não necessariamente a data em que esta quebra foi identificada refere-se ao período exato em que ocorreu a conversão na cobertura da terra.

Figura 9 - Perfil temporal de três objetos da série TMRE/RE\_mean, para diferentes valores de magnitude.



### 3.3 Relação entre os limites de magnitude e as matrizes de confusão

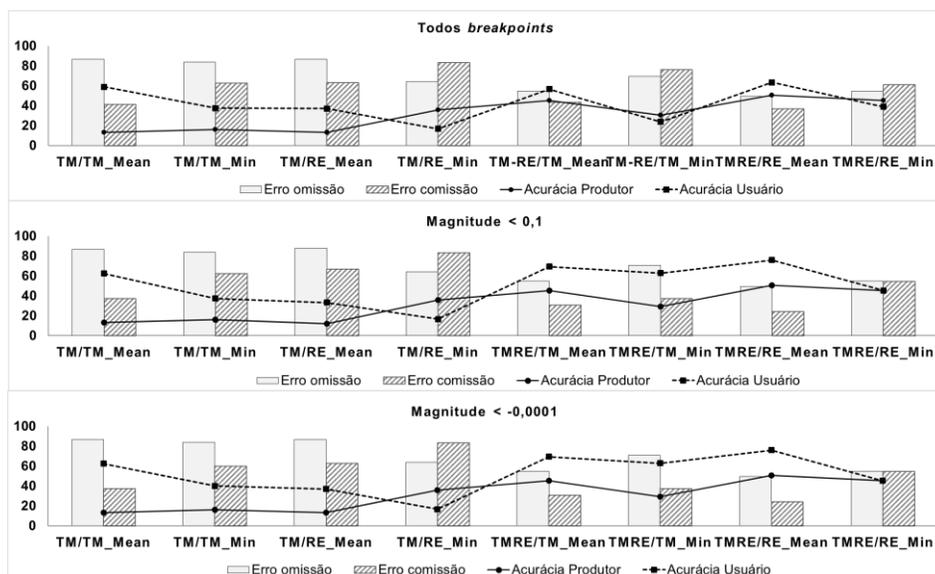
Para avaliar a precisão dos resultados provenientes do BFAST Monitor, as matrizes de confusão foram elaboradas considerando todos os *breakpoints* detectados, assim como somente aqueles com magnitude  $< -0,0001$  e magnitude

$< 0,1$ . A influência dos limites de magnitude na detecção de *breakpoints* em relação às oito séries temporais baseadas em objeto é mostrada na Figura 10.

Independente da série temporal, os limites de magnitude não influenciaram a acurácia do produtor, ou seja, não houve uma alteração relevante no número de objetos de desmatamento identificados corretamente pelo algoritmo. No entanto, este parâmetro influenciou positivamente a acurácia do usuário, evidenciando que as principais alterações foram observadas para as séries temporais com um período histórico multissensor.

Neste caso, observa-se que os limites de magnitude reduziram o erro de comissão e, conseqüentemente, houve um aumento na acurácia do usuário. Na série temporal TMRE/TM\_min nota-se uma drástica redução na porcentagem de *breakpoints* detectados, ocorrendo um decréscimo de 40% a partir do limite de magnitude  $< 0,1$ . Esta condição resultou em um aumento na precisão da acurácia do usuário de 24% para 63%. Já para as séries temporais TMRE/TM\_mean, TMRE/RE\_mean e TMRE/RE\_min, a partir deste limite de magnitude, a redução do erro de comissão resultou em um aumento de cerca de 10% da acurácia do usuário.

Figura 10 - Valor percentual dos parâmetros extraídos a partir da matriz de confusão para os breakpoints detectados considerando os limites de magnitude.



A partir destes resultados, foi evidenciado que a combinação entre *breakpoint*+magnitude foi fundamental para aprimorar a detecção dos desmatamentos na Mata Atlântica. Resultado semelhante foi observado por DeVries et al. (2015), combinando estes dois parâmetros para a detecção de distúrbios de pequena escala em uma região de floresta montana, na Etiópia. Os autores evidenciaram que a magnitude foi uma variável significativa para a distinção entre classes de mudança na vegetação.

Embora, neste trabalho, não tenha ocorrido uma alteração na acurácia do produtor aplicando os limites de magnitude, a inserção deste parâmetro foi fundamental para remover os *breakpoints* decorrentes de variações sazonais na vegetação. Portanto, infere-se que utilizar apenas a detecção de *breakpoints* como um indicativo de mudança não é suficiente para monitorar os desmatamentos de pequena escala na vegetação de ecossistemas tropicais.

### 3.4 Influência das imagens RapidEye na detecção dos desmatamentos

A metodologia baseada em objeto proposta neste trabalho para a análise de séries temporais, além de reduzir o tempo computacional, também permitiu a combinação de imagens de média e alta resolução espacial. Diante disso, para avaliar a influência das imagens RapidEye na detecção automática de desmatamentos, as matrizes de confusão foram calculadas para as oito séries temporais. Diante da relação entre *breakpoint* e magnitude avaliada anteriormente, os resultados para acurácia do produtor e do usuário, assim como os erros de omissão e comissão, são apresentados considerando apenas os *breakpoints* com magnitude  $< -0,0001$  (Tabela 4).

Avaliando estes parâmetros na Figura 10, observa-se um aumento na acurácia do produtor após a substituição de imagens TM por imagens RapidEye. Além disso, observa-se um comportamento distinto em relação aos dois períodos históricos considerados nas análises. O índice de acerto do BFAST Monitor para as séries temporais construídas com um período histórico multissensor alcançou uma acurácia do produtor entre 45% (TMRE/TM\_mean) e 51% (TMRE/RE\_mean). Já para as séries temporais somente com imagens TM (TM/TM\_mean e TM/TM\_min), o algoritmo detectou em média 15% do total de desmatamentos identificados em 2011. Similarmente, a substituição de imagens TM por imagens RapidEye apenas no período de monitoramento não atingiu um resultado satisfatório. Embora tenha ocorrido um aumento na acurácia do produtor, o uso de imagens TM como referência para o monitoramento das imagens de alta resolução espacial resultou em uma detecção máxima de 36% (TM/RE\_min).

No entanto, a inserção de imagens de ambos os sensores de forma conjunta no período histórico acarretou em um aumento relevante na detecção automática dos objetos de desmatamento. A construção de um período histórico

multissensor resultou em uma acurácia do produtor três vezes superior para a série temporal TMRE/TM\_mean (45%), em relação à obtida para a série TM/TM\_mean (13%). Isso indica que, embora a área de estudo seja caracterizada por uma paisagem altamente fragmentada, o monitoramento aplicando séries temporais com imagens de média resolução espacial é possível, desde que imagens de alta resolução espacial sejam incluídas no contexto histórico da dinâmica da vegetação. Esta combinação potencializou o ajuste do modelo de tendência-sazonalidade.

Tabela 4 - Valor percentual para as acurácias do produtor e do usuário, assim como para os erros de omissão e comissão, considerando os breakpoints com magnitude  $< -0,0001$ , detectados nas oito séries temporais baseadas em objetos.

Série temporal	Acurácia		Erro	
	Produtor	Usuário	Omissão	Comissão
<b>TM / TM_mean</b>	13,33	62,50	86,67	37,50
<b>TM / TM_min</b>	16	40	84	60
<b>TM / RE_mean</b>	13,33	37,04	86,67	62,96
<b>TM / RE_min</b>	36	16,77	64	83,23
<b>TMRE / TM_mean</b>	45,33	69,39	54,67	30,61
<b>TMRE / TM_min</b>	29,33	62,86	70,67	37,14
<b>TMRE / RE_mean</b>	50,67	76	49,33	24,00
<b>TMRE / RE_min</b>	45,33	45,33	54,67	54,67

A partir da análise da trajetória temporal de um objeto de desmatamento é possível compreender como as imagens RapidEye aprimoraram a detecção dos desmatamentos na Mata Atlântica (Figura 11 e Figura 12). Entre os quatro perfis temporais a detecção de *breakpoint* só ocorreu após a inserção destas imagens no período histórico e/ou no período de monitoramento. Os gráficos 11A e 11B representam a trajetória do mesmo objeto para as séries temporais TM/TM\_mean e TM/RE\_mean, respectivamente. Em ambos os casos, apesar do denso volume de dados, a resolução espacial das imagens TM ampliou a

variabilidade do período histórico estável identificado, influenciando negativamente no ajuste do modelo de tendência-sazonalidade. Neste caso, as variações na dinâmica da vegetação anteriores a 2002 (evidenciando principalmente as modificações ocorridas entre 1999 e 2001), foram incluídas no período histórico estável.

Como a detecção de mudanças no período de monitoramento é dependente do modelo de regressão ajustado, a queda nos valores de NDVI em 2011 não foi suficiente para rejeitar a hipótese de estabilidade estrutural. Portanto, mesmo com a substituição por imagens RapidEye no período de monitoramento (TM/RE\_mean), o modelo ajustado não forneceu o detalhamento necessário para identificar as variações nos valores de NDVI, condicionando na omissão deste objeto. Diante disso, foi constatado que o uso de apenas imagens TM como referência para obter o comportamento estável da vegetação não foi eficiente para monitorar os desmatamentos de pequena escala.

Quatro condições do modelo de regressão ajustado, considerando a combinação entre imagens TM e RapidEye de um mesmo objeto de desmatamento, estão ilustradas nas Figuras 11 e 12. No Gráfico 12A observa-se a influência positiva da inserção das imagens RapidEye no período histórico, para o monitoramento de imagens TM. Neste caso, a substituição das imagens TM de 2009 e 2010 por imagens RapidEye determinou um ajuste mais robusto para o modelo de regressão, o qual foi obtido considerando um período histórico estável contabilizado a partir de 2002. A exclusão das variações espectrais anteriores a este período aprimorou o refinamento do modelo incidindo na detecção do *breakpoint*. Já no gráfico 12B, o período histórico multissensor foi combinado com imagens RapidEye também para o ano de 2011 (TMRE/RE\_mean). Neste caso, embora a redução no valor de NDVI tenha ocorrido na última observação do período avaliado, ainda assim a variação foi

suficiente para resultar em um desvio significativo, também ocasionando na detecção do *breakpoint*.

Figura 11 - Comparação entre dois perfis temporais para um mesmo objeto de desmatamento, a partir dos valores médios de NDVI. Ambas as séries temporais têm um período histórico constituído somente por imagens TM. No gráfico A está representada a série temporal TM/TM\_mean e, no gráfico B, a série temporal TM/RE\_mean.

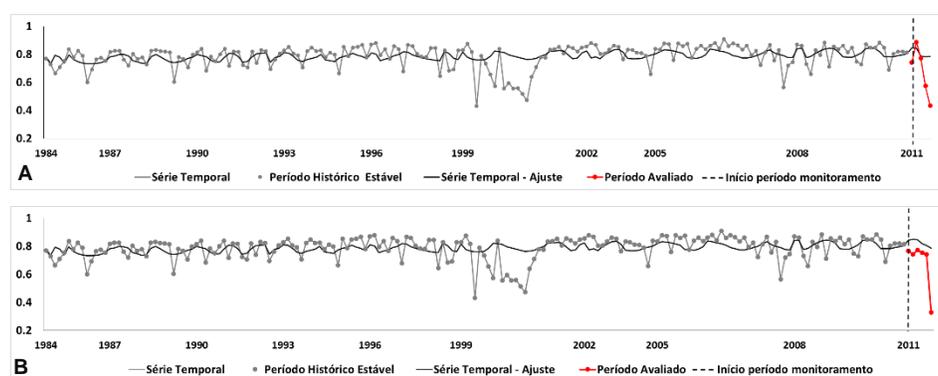
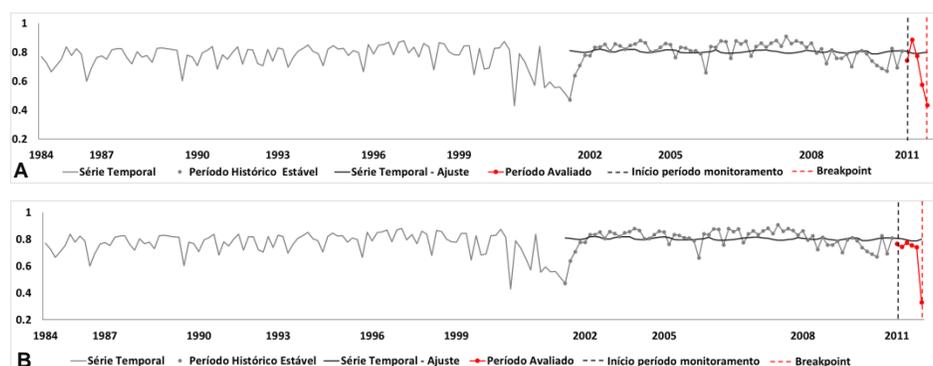


Figura 12 - Comparação entre dois perfis temporais para um mesmo objeto de desmatamento, a partir dos valores médios de NDVI. Ambas as séries temporais têm um período histórico multissensor, constituído por imagens TM e RapidEye. No gráfico A, está representada a série temporal TMRE/TM\_mean e, no gráfico B, a série temporal TMRE/RE\_mean.



Em síntese, os melhores resultados foram obtidos quando imagens RapidEye foram inseridas tanto no contexto histórico quanto no período monitorado. Entre as oito séries temporais avaliadas, a série TMRE/RE\_mean apresentou a maior acurácia do produtor (51%), com probabilidade de acerto de 76% em uma verificação de campo. Em comparação, o monitoramento da vegetação na Etiópia utilizando imagens ETM<sup>+</sup> atingiu uma acurácia do produtor e do usuário de 73% (DEVRIES et al., 2015). Assim como a Mata Atlântica, a área avaliada também consiste em uma floresta tropical úmida. No entanto, os autores descrevem que padrões sazonais complexos não foram observados e, portanto, o modelo de regressão foi elaborado considerando apenas a componente harmônica (sazonalidade). Tendo em vista que, neste estudo, a dinâmica da vegetação adequou-se melhor ao modelo de regressão com as componentes de tendência e sazonalidade, as variações distintas no comportamento da vegetação entre ambas as áreas podem ter influenciado na detecção automática dos desmatamentos.

Além disso, os estudos realizados nestas formações florestais no território nacional elucidam a necessidade de aprimorar os monitoramentos realizados com imagens de baixa e média resolução espacial. Os resultados obtidos neste trabalho para as séries temporais construídas somente com imagens TM corroboram os resultados obtidos por Stephan (2015). Neste caso, a análise de uma série temporal EVI/MODIS pelo BFAST Monitor resultou na detecção de apenas 7% dos pequenos desmatamentos, ocorridos em uma região da Floresta Amazônica.

Diante disso, é importante ressaltar que este trabalho corresponde ao primeiro estudo referente à análise de séries temporais de imagens de alta resolução espacial, aplicando o BFAST Monitor. Embora os resultados obtidos ainda sejam inferiores aos observados no monitoramento de outras formações florestais, estes consistem em um grande avanço para o monitoramento de

florestas tropicais úmidas no território nacional. Enquanto séries temporais com imagens TM foram capazes de detectar, em média, 15% dos desmatamentos na Mata Atlântica, a abordagem multissensor TM/RapidEye aumentou o índice de acerto para 51%.

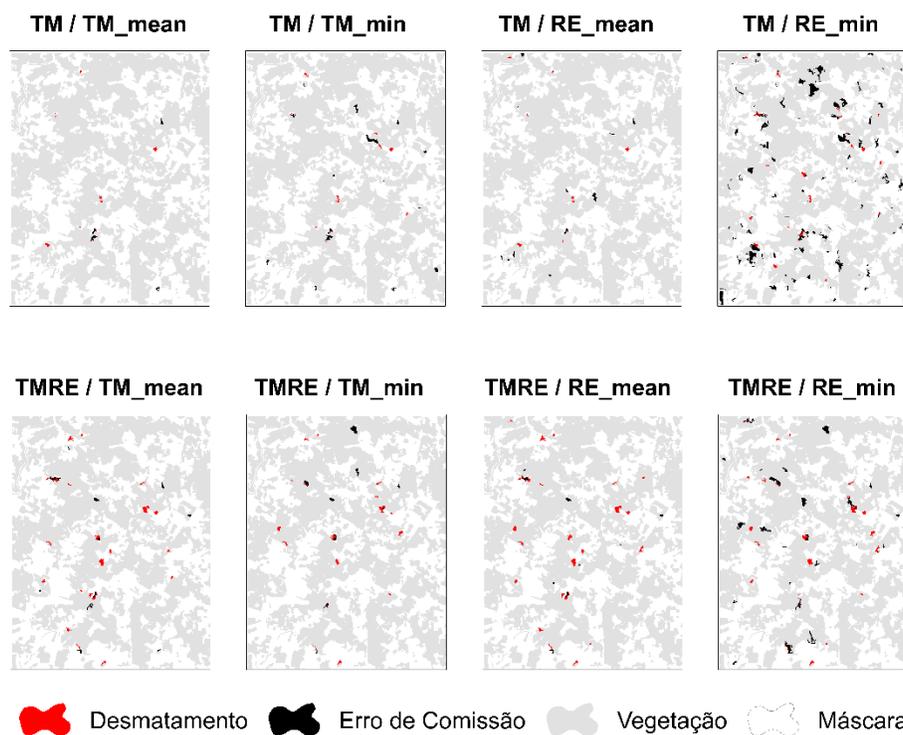
### **3.5 Principais fontes de erros na detecção de *breakpoints***

#### **3.5.1 Parâmetros estatísticos e o erro de comissão**

O uso da abordagem baseada em objeto para a construção das séries temporais permitiu testar a capacidade de detecção de desmatamentos pelo BFAST Monitor, considerando diferentes parâmetros estatísticos. Foi observado que as séries temporais construídas com os valores mínimos apresentaram uma maior frequência de objetos detectados incorretamente como desmatamento em relação às séries temporais equivalentes com os valores médios (Figura 13).

Considerando apenas os *breakpoints* com magnitude  $< -0,0001$  e as séries temporais com imagens RapidEye, o erro de comissão da série TMRE/RE\_min foi cerca de 30% maior em relação à série temporal TMRE/RE\_mean. Além disso, os parâmetros estatísticos também influenciaram as séries temporais com resoluções espaciais diferentes. As séries temporais TMRE/TM\_mean e TMRE/RE\_min têm um mesmo período histórico, sendo distinguidas pela resolução espacial das imagens no período de monitoramento e pelo parâmetro estatístico avaliado. Neste caso, ambas as séries temporais apresentaram a mesma acurácia do produtor (45%). No entanto, a acurácia do usuário da série com imagens TM no período de monitoramento foi de 70%, enquanto da série com imagens RapidEye foi de apenas 45%. Neste caso, apesar da melhor resolução espacial, o erro de comissão para a série temporal construída com os valores mínimos (TMRE/RE\_min) foi quase duas vezes maior do que o observado para a série temporal TMRE/TM\_mean.

Figura 13 - Erro de comissão para as oito séries temporais, considerando os breakpoints com uma magnitude  $< -0,0001$ . Em vermelho estão representados os objetos de desmatamento que foram detectados corretamente pelo BFAST Monitor, enquanto os objetos na cor preta representam aqueles detectados incorretamente. A área em cinza consiste na região de vegetação que não foi alterada no período avaliado e as áreas em branco incluem as áreas mascaradas nas análises.



O comportamento distinto entre estes parâmetros pode ser atribuído à maneira de aquisição dessas informações. A média é extraída considerando todos os pixels incluídos na delimitação do objeto, ou seja, este valor sempre será resultante do mesmo conjunto de dados. Já o mínimo refere-se a um único pixel, sendo correspondente ao menor valor de NDVI dentro do objeto. Como as análises consistem na construção de séries temporais, a extração deste parâmetro pode ser alternada entre os vários pixels incluídos no objeto, ao longo das

imagens da série temporal. Isso pode ter dificultado a definição de um comportamento padrão, conduzindo a falsas detecções, devido a uma maior variabilidade na trajetória ao longo do tempo de algumas áreas florestais. Portanto, foi constatado que a média correspondeu ao melhor parâmetro estatístico para a detecção de desmatamentos na Mata Atlântica, devido à sua menor influência do erro de comissão.

Em um estudo recente, Hamunyela, Verbesselt e Herold (2016) desenvolveram uma abordagem baseada no contexto espacial para reduzir a influência sazonal no monitoramento de ecossistemas tropicais. A comparação do método utilizando séries temporais NDVI/TM evidenciou que o método proposto reduziu o erro de comissão na detecção de desmatamentos em uma floresta tropical seca, entretanto, não foram observados resultados relevantes para a floresta tropical úmida. Diante disso, os resultados deste trabalho indicam que a abordagem baseada em objeto utilizando os valores médios de NDVI consiste em novo subsídio para melhorar a precisão dos monitoramentos de florestas tropicais úmidas.

### **3.5.2 Magnitude e o erro de omissão**

A omissão de objetos de desmatamento foi preeminente em todas as séries temporais (Figura 14). Infere-se que a alta incidência do erro de omissão esteve relacionada à frequência de objetos de desmatamento/classe de magnitude (Figura 15). Neste estudo, como a análise considera diferentes parâmetros estatísticos e sensores avaliados, o número de objetos/classe de magnitude é distinto para cada série temporal.

Figura 14 - Erro de omissão para as oito séries temporais, considerando os breakpoints com magnitude  $<-0,0001$ . Em vermelho estão representados os objetos de desmatamento que foram detectados corretamente pelo BFAST Monitor, enquanto os objetos na cor preta foram omitidos. A área em cinza consiste na região de vegetação que não foi alterada no período avaliado e as áreas em branco incluem as áreas mascaradas nas análises.

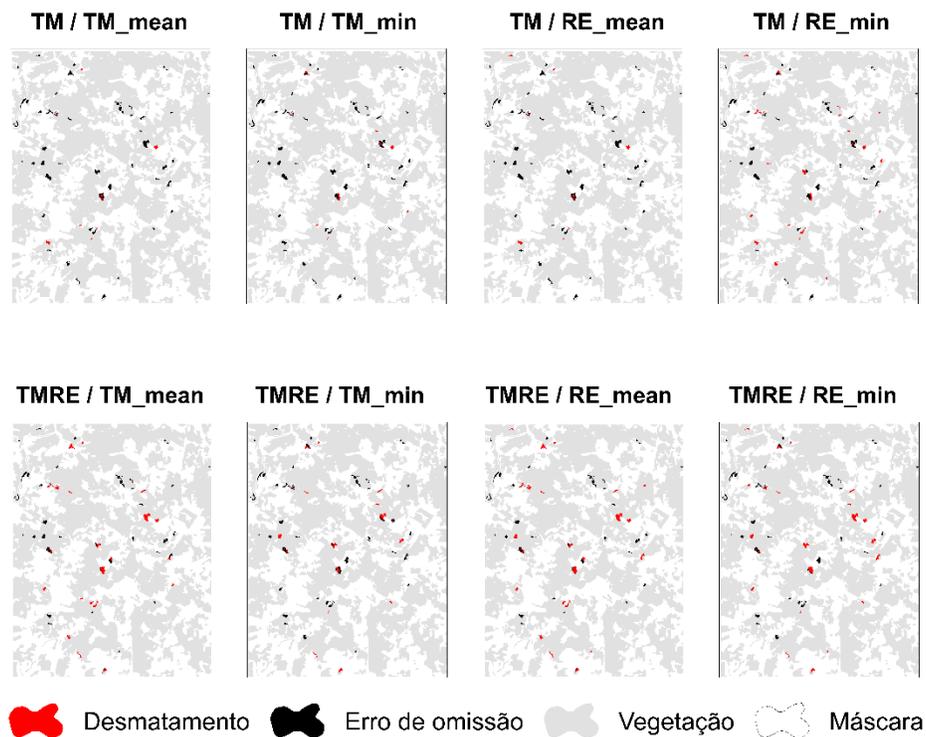
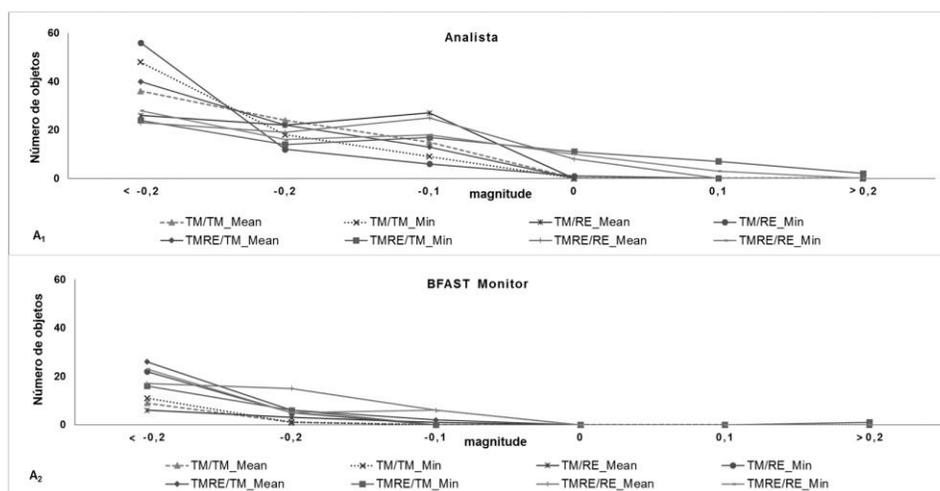


Figura 15 - Número de objetos de desmatamento/classe de magnitude, identificados pelo intérprete e detectados pelo BFAST Monitor.



Independente da série temporal avaliada, a relação entre os objetos identificados pelo intérprete e detectados pelo BFAST Monitor evidenciou um decréscimo na detecção dos desmatamentos com uma magnitude  $> -0,1$ . Diante disso, foi constatado que a probabilidade de detecção de um *breakpoint* associado a um objeto de desmatamento foi inversamente proporcional ao valor da magnitude. Esta condição pode ter influenciado o erro de omissão, uma vez que, para as oito séries temporais, houve alta frequência de objetos de desmatamento com uma magnitude superior a este valor.

Considerando a relação de todas as séries temporais, foi observada uma média de 12 objetos com magnitude  $> -0,1$ . A menor e a maior frequência foram identificadas para as séries  $TM/RE\_min$  (7 objetos) e  $TMRE/TM\_min$  (37 objetos). Contudo, a detecção média do BFAST Monitor a partir deste valor de magnitude foi de apenas um objeto de desmatamento. O máximo de seis objetos foi obtido para as séries temporais com imagens RapidEye ( $TMRE/RE\_mean$  e

TMRE/RE\_min). Já para as séries TM/TM\_mean, TM/TM\_min e TM/RE\_min, o algoritmo não detectou nenhum objeto incluído neste intervalo.

Em detrimento desta baixa detecção de objetos com magnitude  $>-0,1$ , o erro de omissão das séries temporais com um período histórico multissensor variou entre 50% (TMRE/RE\_mean) e 70% (TMRE/TM\_min), enquanto para as séries com um período histórico TM, atingiu até 87% (TM/TM\_mean), (Tabela 4). Também para a série temporal TMRE/RE\_mean, a qual apresentou a maior acurácia do produtor (51%), foi observado que 44% dos objetos identificados pelo intérprete apresentaram magnitude  $>-0,1$ . Entretanto, apenas seis objetos foram identificados como *breakpoints* neste intervalo. Em contraste, 76% dos objetos com magnitude  $<-0,2$  foram detectados corretamente.

Estes resultados indicam que a capacidade de detecção dos desmatamentos pelo BFAST Monitor foi influenciada pelos valores de magnitude. Assim como observado por DeVries et al. (2015), a incidência de falsos negativos pode ser devido a uma incoerência entre os valores deste parâmetro e a condição real do desmatamento. Presume-se que houve uma relação divergente da condição esperada, pois, como a mudança de interesse corresponde a uma remoção da cobertura total da vegetação, os objetos de desmatamento identificados pelo intérprete não deveriam apresentar magnitude próxima a zero (comportamento estável) (Tabela 5).

No entanto, as análises realizadas neste trabalho não fornecem subsídios para identificar quais fatores condicionaram esta divergência, mas infere-se que o comportamento desses objetos pode ser decorrente de desmatamentos que ocorreram ao final do período de monitoramento (Figura 16). Esta suposição é fundamentada no conceito do método de detecção aplicado. Neste caso, a baixa sensibilidade do algoritmo para detectar estes objetos pode ser explicada pelos limites da janela de soma móvel (MOSUM), os quais desviam de zero com uma função do tempo. Dessa maneira, para que a hipótese de estabilidade estrutural

possa ser rejeitada e um *breakpoint* ser detectado para desmatamentos que ocorreram ao final do período de monitoramento, é necessário que a magnitude da mudança seja suficientemente grande para compensar o comportamento padrão anterior a este decréscimo, resultando em um desvio significativo (DUTRIEUX et al., 2015).

Figura 16 - Trajetória temporal de um objeto de desmatamento que não foi detectado pelo BFAST Monitor.

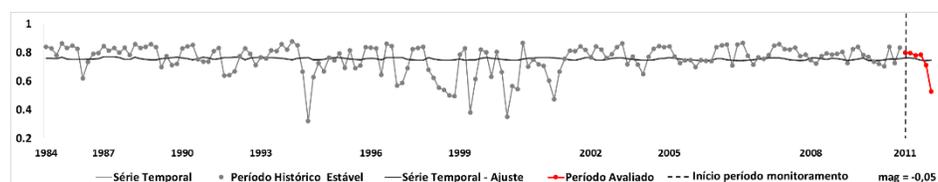


Tabela 5 - Relação dos 75 objetos de desmatamento detectados pelo intérprete, classificados de acordo com seu valor de magnitude.

Série Temporal	Classes magnitude					
	< -0,2	-0,2	-0,1	0	0,1	> 0,2
TM/TM_mean	36	24	15	-	-	-
TM/TM_min	48	18	9	-	-	-
TM/RE_mean	26	22	27	-	-	-
TM/RE_min	56	12	6	1	-	-
TMRE/TM_mean	40	22	13	-	-	-
TMRE/TM_min	24	14	17	11	7	2
TMRE/RE_mean	23	19	25	8	-	-
TMRE/RE_min	28	16	18	10	3	-

Uma alternativa para obter resultados mais robustos consiste na metodologia aplicada por Dutriex et al. (2015). Os autores melhoraram o resultado da análise de uma série temporal  $ETM^+/TM$  utilizando o BFAST Monitor, a partir da inserção de uma série temporal NDVI/MODIS como um parâmetro de regressão externo ao modelo de tendência-sazonalidade ajustado.

Esta abordagem aumentou a detecção de desmatamentos que ocorreram ao final do período de monitoramento, reduzindo o erro de omissão. Diante disso, este método representa uma ferramenta para diminuir a ocorrência de falsos-negativos.

No entanto, imagens do sensor MODIS têm uma resolução espacial variando entre 250-100 m e, portanto, este banco de dados não é representativo dos distúrbios avaliados neste estudo, uma vez que o tamanho dos objetos de desmatamento compreendeu uma área entre 0,14 e 1,7 ha. Contudo, TEWES et al., 2015 aplicaram o método *Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model* (ESTARFM) para a fusão de imagens MODIS/RapidEye, obtendo resultados satisfatórios para imagens NDVI. Dessa maneira, o uso de imagens sintéticas consiste em uma alternativa para obter uma série temporal com alta frequência de dados e alta resolução espacial, sendo uma referência para a elaboração de um parâmetro externo ao modelo ajustado, o que pode auxiliar na redução de falsos negativos.

### **3.6 Limitações e pesquisas futuras**

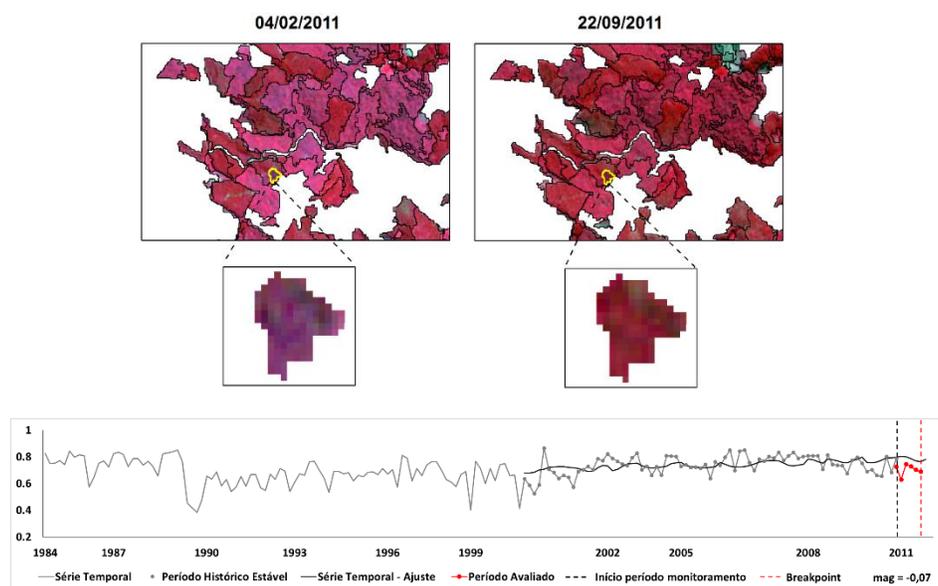
Os resultados obtidos elucidaram um grande potencial da metodologia proposta, uma vez que esta foi eficiente para a detecção de pequenos desmatamentos na Mata Atlântica. No entanto, novos estudos precisam ser direcionados para reduzir os erros de comissão e omissão.

Neste trabalho, é importante ressaltar que os desmatamentos foram caracterizados como a remoção da cobertura florestal da vegetação nativa ou plantada, o que correspondeu a um fator limitante nas análises do BFAST Monitor. A forma como esta condição influenciou no erro de comissão está ilustrada na Figura 17. Neste caso, o objeto analisado consiste em uma área de floresta plantada em que a trajetória temporal resultou na detecção incorreta de

um *breakpoint* pelo BFAST Monitor. O manejo destas áreas pode resultar em variações acentuadas no padrão de reflectância destas feições, determinando uma variação nos valores de NDVI devido às alterações no seu padrão espectral.

Esta condição pode ter contribuído para a detecção de *breakpoints* correspondentes a falsos positivos, nas oito séries temporais avaliadas. Portanto, recomenda-se que, em estudos futuros, uma máscara de vegetação seja aplicada no intuito de direcionar as análises apenas para as áreas naturais ou manejadas. Neste estudo, esta possibilidade foi desconsiderada devido à ausência de dados de verdade de campo, o que dificultou a distinção dessas formações florestais.

Figura 17 - Exemplo da influência sazonal objeto de floresta plantada. Imagens RapidEye do ano de 2011, em uma composição RGB 5-3-2.



Além disso, deve-se ressaltar que ainda é necessário investigar se o decréscimo na detecção de objetos que apresentaram magnitude  $>-0,1$  é característico de objetos de desmatamento com um processo gradual de mudanças na cobertura da terra e, portanto, há menor discrepância entre os

desvios dos valores observados e esperados ou se este valor é decorrente de desmatamentos que ocorreram ao final do período avaliado. Neste último caso, a análise restrita ao monitoramento de um único ano (2011) foi identificada como uma possível limitação. Presume-se que esta condição pode ter influenciado a omissão de desmatamentos que ocorreram ao final do período monitorado.

Diante disso, a realização de monitoramentos sequenciais, como proposto por DeVries et al. (2015), corresponde a uma alternativa para ser implementada em novos estudos. Neste trabalho foi avaliado apenas o ano de 2011, no entanto, estender o monitoramento para os anos subsequentes poderia aumentar a capacidade de detecção destes desmatamentos, resultando em uma acurácia do produtor mais robusta. Também no intuito de refinar os resultados já obtidos, é recomendável testar novos parâmetros para o modelo de tendência-sazonalidade. DeVries et al. (2015) inferiram um possível *trade-off* entre a ordem da componente harmônica e os erros de comissão e omissão. Nesta relação foi observado que a redução da ordem desta componente diminuiu o erro de comissão, entretanto, isso acarretou em um aumento no erro de omissão. Neste trabalho, foi utilizada uma abordagem mais conservadora (componente harmônica de ordem = 1), no entanto, análises com novas combinações ainda são necessárias para obter um modelo ideal para o monitoramento de florestas tropicais.

#### 4 CONSIDERAÇÕES FINAIS

Este estudo foi desenvolvido fundamentando-se no pressuposto de que imagens de média resolução espacial (TM) não corresponderiam a um banco de dados representativo para o monitoramento de pequenos desmatamentos em florestas tropicais. Tal suposição foi confirmada com os resultados obtidos após a inserção de imagens RapidEye, na construção das séries temporais. A nova metodologia foi eficiente para o monitoramento de desmatamentos na Mata Atlântica, resultando em um aumento na detecção automática. Deve-se ressaltar que a abordagem de imagens-objeto foi fundamental para a redução expressiva do tempo computacional. Além disso, esta metodologia pode ser implementada para outros sensores remotos, o que evidencia a sua viabilidade de implementação em diversos estudos.

Em síntese, os melhores resultados foram caracterizados pela utilização das séries temporais com imagens-objeto construídas com os valores médios de NDVI e com um período histórico multissensor integrado a um período de monitoramento com imagens de alta resolução espacial. Também foi evidenciado que a detecção de *breakpoints* não foi suficiente para a caracterização dos objetos de desmatamento. Neste caso, a combinação entre os parâmetros *breakpoint* + magnitude foi fundamental para reduzir a influência do erro de comissão. Com esta combinação, a menor influência de falsos positivos foi obtida considerando apenas os *breakpoints* com magnitude  $< -0,0001$ . Além disso, também foi identificado que os objetos de desmatamento com magnitude  $< -0,2$  apresentaram uma maior probabilidade de serem detectados.

Diante destes resultados, a metodologia proposta elucidou uma nova perspectiva para o monitoramento de amplas extensões territoriais e com grande interferência antrópica em suas áreas naturais. Além disso, esta metodologia

apresenta grande potencial para ser utilizado em projetos de gestão pública e ambiental, a fim de monitorar os ecossistemas tropicais.

## 5 CONCLUSÃO

Este estudo foi desenvolvido no intuito de elaborar uma metodologia para aprimorar a detecção automática de pequenos desmatamentos em florestas tropicais. Diante disso, foi apresentada uma metodologia para a análise de séries temporais aplicando uma abordagem multissensor e baseada em objeto, priorizando a redução do tempo computacional. O método para a construção de imagens-objeto foi aplicado para a combinação de imagens TM e RapidEye. Além disso, para avaliar como imagens de alta resolução espacial poderiam melhorar a detecção automática de pequenos desmatamentos em uma área na Mata Atlântica, oito séries temporais foram construídas e analisadas utilizando o BFAST Monitor. Em síntese, as principais conclusões provenientes deste trabalho foram:

- a) a construção de imagens-objeto foi fundamental para a redução do tempo de processamento das séries temporais no BFAST Monitor. Esta abordagem determinou uma redução de 95% no tempo de processamento, em relação à análise em nível de pixel. Além disso, este método possibilitou integrar imagens de média e alta resolução espacial, determinando um aumento na detecção automática dos desmatamentos;
- b) o período histórico formado apenas por imagens TM não foi adequado para obter um comportamento representativo da estabilidade da dinâmica da vegetação. Neste caso, a abordagem multissensor resultou em um aumento na detecção dos desmatamentos, uma vez que a inserção de imagens RapidEye neste período contribuiu para o aumento da acurácia do produtor, independente do sensor (TM ou RapidEye) utilizado no período de monitoramento;

- c) a inserção de imagens de alta resolução espacial aprimorou a detecção dos pequenos desmatamentos. Os melhores resultados para detecção automática pelo BFAST Monitor foram obtidos com imagens RapidEye inseridas no período histórico e no período de monitoramento. Neste caso, a acurácia do produtor foi aumentada em até quatro vezes, detectando até 51% dos desmatamentos identificados na área avaliada;
- d) a combinação entre *breakpoint*+magnitude influenciou positivamente a acurácia do usuário. Considerando somente os *breakpoints* com magnitude  $< -0,0001$ , a probabilidade de acerto em uma verificação de campo alcançou até 76%;
- e) os parâmetros estatísticos apresentaram resultados distintos para a detecção dos objetos de desmatamento pelo BFAST Monitor. Os melhores resultados foram obtidos utilizando-se os valores médios de NDVI. As séries temporais construídas com os valores mínimos apresentaram uma maior influência do erro de comissão;
- f) a construção de séries temporais multissensor TM/RapidEye utilizando uma abordagem baseada em objeto elucidou um novo subsídio para o monitoramento da vegetação. O método proposto representa uma nova alternativa para estudos em áreas de ampla extensão territorial, com maior precisão no monitoramento de desmatamentos de pequena escala.

## REFERÊNCIAS

- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 65, n. 1, p. 2-16, Jan. 2010.
- BRASIL. Ministério do Meio Ambiente. **Código Estadual do Meio Ambiente Santa Catarina**: Lei nº 14.675, de 13 de abril de 2009. Parecer nº 005/SBF/MMA/2009. Brasília, DF, 2009. 146 p.
- BROOKS, E. B. et al. On-the-fly massively multitemporal change detection using statistical quality control charts and Landsat data. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 52, n. 6, p. 1-17, 2013.
- COHEN, W. B.; GOWARD, S. N. Landsat's role in ecological applications of remote sensing. **BioScience**, Washington, v. 54, n. 6, p. 535-545, 2004.
- DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, New York, v. 102, n. 1/2, p. 1-11, 2006.
- DEVRIES, B. et al. Robust monitoring of small-scale forest disturbances in a tropical montane forest using landsat time series. **Remote Sensing of Environment**, New York, v. 161, p. 107-121, May 2015.
- DUTRIEUX, L.; DEVRIES, B.; VERBESSELT, J. **bfastSpatial**: utilities to monitor for change on satellite image time-series. R Package Version 0.6.1. 2014.
- DUTRIEUX, L. P. et al. Monitoring forest cover loss using multiple data streams, a case study of a tropical dry forest in Bolivia. **ISPRS Journal of Photogrammetry and Remote Sensing**, Beijing, v. 107, p. 112-125, Sept. 2015.
- DUTRIEUX, L. P. et al. Reconstructing land use history from Landsat time-series case study of a swidden agriculture system in Brazil. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 47, p. 112-124, May 2016.

FANG, X. et al. Large-scale detection of vegetation dynamics using MODIS images and BFAST: a case study in Quebec, Canada. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, New York, p. 768-771, July 2014.

FRAGAL, E. H. et al. Reconstructing historical forest cover change in the Lower Amazon floodplains using the LandTrendr algorithm. **Acta Amazonica**, Manaus, v. 46, n. 1, p. 13-24, Jan. 2016.

GEIST, H. J.; LAMBIN, E. F. Proximate causes and underlying driving forces of tropical deforestation: tropical forests are disappearing as the result of many pressures, both local and regional, acting in various combinations in different geographical locations. **BioScience**, Washington, v. 52, n. 2, p. 143-150, 2002.

GOMES, M. F.; MAILLARDA, M. Using spectral and textural features from RapidEye images to estimate age and structural parameters of Cerrado vegetation. **International Journal of Remote Sensing**, Basingstoke, v. 36, n. 12, p. 3058-3076, July 2015.

HAMUNYELA, E.; VERBESSELT, J.; HEROLD, M. Using spatial context to improve early detection of deforestation from Landsat time series. **Remote Sensing of Environment**, New York, v. 172, p. 126-138, Jan. 2016.

HANSEN, M. C. et al. High-resolution global maps of 21st-century forest cover change. **Science**, New York, v. 342, n. 6160, p. 850-853. 2013.

HANSEN, M. C.; LOVELAND, T. R. A review of large area monitoring of land cover change using Landsat data. **Remote Sensing of Environment**, New York, v. 122, p. 66-74, July 2012.

HUANG, C. et al. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. **Remote Sensing of Environment**, New York, v. 114, n. 1, p. 183-198, Jan. 2010.

HUANG, X.; FRIEDL, M. A. Distance metric-based forest cover change detection using MODIS time series. **International Journal of Applied Remote Sensing and Geoinformation**, Enschede, v. 29, p. 78-92, June 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico da vegetação brasileira**. Rio de Janeiro, 2012. 271 p.

JACQUIN, A.; SHEEREN, D.; LACOMBE, J. P. Vegetation cover degradation assessment in Madagascar savanna based on trend analysis of MODIS NDVI time series. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 12, p. 3-10, 2010. Supplement 1.

JIN, S. et al. A comprehensive change detection method for updating the National Land Cover Database to circa 2011. **Remote Sensing of Environment**, New York, v. 132, p. 159-175, May 2013.

KENNEDY, R. E. et al. Spatial and temporal patterns of forest disturbance and regrowth within the area of the Northwest Forest Plan. **Remote Sensing of Environment**, New York, v. 122, p. 117-133, July 2012.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1., LandTrendr - temporal segmentation algorithms. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2897-2910, 2010.

KLEIN, R. M. **Mapa fitogeográfico do estado de Santa Catarina**. Itajaí: SUDESUL, 1978. 24 p. (Flora Ilustrada Catarinense, 5).

LOVELAND, T. R.; DEFRIES, R. Observing and monitoring land use and land cover change. In: DEFRIES, R.; ASNER, G.; HOUGHTON, R. (Ed.). **Ecosystems and land use change, geophysical monograph series**. Washington, DC: American Geophysical Union, 2004. p. 231-246.

LU, D.; LI, G.; MORAN, E. Current situation and needs of change detection techniques. **International Journal of Image and Data Fusion**, London, v. 5, n. 1, p. 13-38, Mar. 2014.

LUNETTA, R. S. et al. Impacts of imagery temporal frequency on land-cover change detection monitoring. **Remote Sensing of Environment**, New York, v. 89, n. 4, p. 444-454, 2004.

MASEK, J. G. et al. A Landsat surface reflectance data set for North America, 1990-2000. **Geoscience and Remote Sensing Letters**, New York, v. 3, n. 1, p. 68-72, Jan. 2006.

MELLO, M. et al. STARS: a new method for multitemporal remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 5, n. 4, p. 1897-1913, Apr. 2013.

MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, London, v. 403, p. 853-858, Feb. 2000.

PESARAN, M. H.; TIMMERMANN, A. Market timing and return prediction under model instability. **Journal of Empirical Finance**, New York, v. 9, n. 5, p. 495-510, Dec. 2002.

POTAPOV, P. V. et al. National satellite-based humid tropical forest change assessment in Peru in support of REDD plus implementation. **Environmental Research Letters**, Berkeley, v. 9, n. 12, p. 1-13, 2014.

QUAC user's guide: atmospheric correction module: QUAC and FLAASH. Version 4.7. ITT Visual Information Solution, 2009.

R CORE TEAM. **R**: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2015. Disponível em: <<http://www.R-project.org/>>. Acesso em: 10 jan. 2014.

REICHE, J. et al. Fusing Landsat and {SAR} time series to detect deforestation in the tropics. **Remote Sensing of Environment**, New York, v. 156, p. 276-293, Jan. 2015.

RIBEIRO, M. C. et al. The Brazilian Atlantic Forest: how much is left, and how is the remaining forest distributed?: implications for conservation. **Biological Conservation**, Essex, v. 142, n. 6, p. 1141-1153, June 2009.

ROGAN, J.; CHEN, D. Remote sensing technology for mapping and monitoring land-cover and land-use change. **Progress in Planning**, New York, v. 61, n. 4, p. 301-325, May 2004.

SINGH, A. Review article digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, Basingstoke, v. 10, n. 6, p. 989-1003, June 1989.

STEPHAN, C. **Automating near real-time deforestation monitoring with satellite image time series**. 2015. 121 p. Thesis (Master of Science in Geoinformatics)-University of Muenster, Muenster, 2015.

SULLA-MENASHE, D. et al. Detecting forest disturbance in the Pacific Northwest from MODIS time series using temporal segmentation. **Remote Sensing of Environment**, New York, v. 151, p. 114-123, Aug. 2014.

TAPSALL, B.; MILENOV, P.; TAŞDEMİR, K. Analysis of rapideye imagery for annual landcover mapping as an aid to European Union (EU) Common Agricultural Policy. In: THE INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, 38., 2010, Vienna. Proceedings... Vienna: The International Archives of the Photogrammetry, 2010. **Remote Sensing and Spatial Information Sciences**, Vienna, v. 38, p. 568-573, 2010.

TEWES, A. et al. Using Rapideye and MODIS data fusion to monitor vegetation dynamics in semi-arid rangelands in South Africa. **Remote Sensing**, New York, v. 7, n. 6, p. 6510-6534, May 2015.

TIGGES, J.; LAKES, T.; HOSTERT, P. Urban vegetation classification: benefits of multitemporal RapidEye satellite data. **Remote Sensing of Environment**, New York, v. 136, p. 66-75, Sept. 2013.

VERBESSELT, J. et al. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 1, p. 106-115, Jan. 2010a.

VERBESSELT, J. et al. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, New York, v. 114, n. 12, p. 2970-2980, Dec. 2010b.

VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, New York, v. 123, p. 98-108, Aug. 2012.

VIBRANS, A. C. et al. Using satellite image-based maps and ground inventory data to estimate the area of the remaining Atlantic forest in the Brazilian state of Santa Catarina. **Remote Sensing of Environment**, New York, v. 130, p. 87-95, Mar. 2013.

WOODCOCK, C. et al. Free access to landsat imagery teach by the book science education . **Science**, New York, v. 320, n. 5879, p. 1011-1012, May 2008.

WULDER, M. A. et al. Continuity of Landsat observations: short term considerations. **Remote Sensing of Environment**, New York, v. 115, n. 2, p. 747-751, Feb. 2011.

ZHAO, F.; HUANG, C.; ZHU, Z. Use of vegetation change tracker and supportvector machine to map disturbance types in greater yellowstone ecosystems in a 1984-2010 Landsat time series. **IEEE Geoscience and Remote Sensing Letters**, New York, v. 12, n. 8, p. 1650-1654, 2015.

ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, New York, v. 144, p. 152-171, Mar. 2014.

ZHU, Z.; WOODCOCK, C. E.; OLOFSSON, P. Continuous monitoring of forest disturbance using all available Landsat imagery. **Remote Sensing of Environment**, New York, v. 122, p. 75-91, July 2012.

## APÊNDICES

APÊNDICE A - Matrizes de confusão considerando os *breakpoints* com magnitude  $< -0,0001$ , para as séries temporais baseadas em objeto construídas com os valores médios de NDVI.

<b>TM / TM_mean</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	Total
Desmatamento	10	6	16
Não mudança	65	1891	1956
Total	75	1897	1972

<b>TM / RE_mean</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	Total
Desmatamento	10	17	27
Não mudança	65	1880	1945
Total	75	1897	1972

<b>TMRE / TM_mean</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	Total
Desmatamento	34	15	49
Não mudança	41	1882	1923
Total	75	1897	1972

<b>TMRE / RE_mean</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	Total
Desmatamento	38	12	50
Não mudança	37	1885	1922
Total	75	1897	1972

APÊNDICE B - Matrizes de confusão considerando os *breakpoints* com magnitude  $< -0,0001$ , para as séries temporais baseadas em objeto construídas com os valores mínimos de NDVI.

<b>TM / TM_min</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	<b>Total</b>
Desmatamento	12	18	30
Não mudança	63	1879	1942
<b>Total</b>	75	1897	1972

<b>TM / RE_min</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	<b>Total</b>
Desmatamento	27	134	161
Não mudança	48	1763	1811
<b>Total</b>	75	1897	1972

<b>TMRE / TM_min</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	<b>Total</b>
Desmatamento	22	13	35
Não mudança	53	1884	1937
<b>Total</b>	75	1897	1972

<b>TMRE / RE_min</b>			
<b>Verdade de campo</b>			
<b>BFAST Monitor</b>	Desmatamento	Não mudança	<b>Total</b>
Desmatamento	34	41	75
Não mudança	41	1856	1897
<b>Total</b>	75	1897	1972