

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

MARCELO BUENO DE ABREU

**Contribuição metodológica para detecção de mudança em
cobertura florestal em mesoescala**

RIO DE JANEIRO

2018

Marcelo Bueno de Abreu

**Contribuição metodológica para detecção de mudança em cobertura florestal em
mesoescala**

Tese de Doutorado apresentada ao
Programa de Pós-Graduação em Geografia
(PPGG) da Universidade Federal do Rio de
Janeiro (UFRJ), como requisito parcial à
obtenção do título de Doutor em Geografia

Orientadora: Carla Bernadete Madureira Cruz

Rio de Janeiro

2018

CIP - Catalogação na Publicação

A162c Abreu, Marcelo Bueno de
Contribuição metodológica para detecção de mudança
em cobertura florestal em mesoescala / Marcelo
Bueno de Abreu. -- Rio de Janeiro, 2018.
106 f.

Orientadora: Carla Bernadete Madureira Cruz.
Tese (doutorado) - Universidade Federal do Rio
de Janeiro, Instituto de Geociências, Programa de
Pós-Graduação em Geografia, 2018.

1. Detecção de mudança. 2. Cobertura florestal. 3.
GEOBIA. 4. Landsat. I. Cruz, Carla Bernadete
Madureira, orient. II. Título.

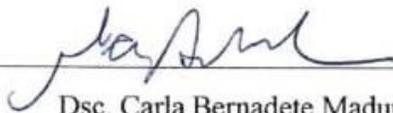
Elaborado pelo Sistema de Geração Automática da UFRJ com os dados fornecidos pelo(a) autor(a), sob a responsabilidade de Miguel Romeu Amorim Neto - CRB-7/6283.

Marcelo Bueno de Abreu

Contribuição metodológica para detecção de mudança em cobertura florestal em mesoescala

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Geografia (PPGG) da Universidade Federal do Rio de Janeiro (UFRJ), como requisito parcial à obtenção do título de Doutor em Geografia

Aprovada em: 15 DE OUTUBRO DE 2018



Dsc. Carla Bernadete Madureira Cruz

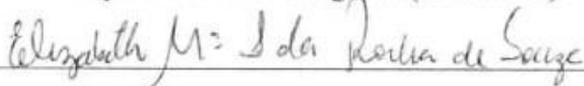
Departamento de Geografia (UFRJ)



Dsc. Paula Maria Moura de Almeida
Escola de formação de professores/Geografia (UCB)



Dsc. Vinicius da Silva Seabra
Departamento de Geografia (UERJ/FFP)



Dsc. Elizabeth Maria Feitosa da Rocha Souza
Departamento de Geografia (UFRJ)



Dsc. Rafael Silva Barros
Departamento de Geografia (UFRJ)

Agradecimentos

Primeiramente gostaria de agradecer a minha família e amigos por todo o apoio ao longo desses quatro anos de pesquisa.

A minha orientadora Carla Madureira por todos os momentos de aprendizado e companheirismo durante a elaboração dessa tese.

Aos membros da banca, Paula Almeida, Elizabeth Rocha, Vinicius Seabra e Rafael Barros por aceitarem o convite de avaliar esse trabalho.

A equipe do laboratório Espaço pelos bons momentos de trabalhos de pesquisa e de campo, de conversas e debates durante esse período do doutorado.

Ao Capes e CNPQ, juntamente com o programa Ciência sem Fronteiras, por proverem as bolsas de estudos que viabilizaram o desenvolvimento da pesquisa e o período de estágio no exterior via bolsa sanduíche.

A Maggi Kelly e os membros do laboratório *Kelly lab Research and Outreach* da Universidade da Califórnia- Berkeley por me receberam durante o período de pesquisa no exterior.

A minha esposa Patricia Nick por me apoiar em todos os momentos e a imensa ajuda durante a etapa final do Doutorado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

Resumo

O debate sobre a elaboração de metodologias voltadas para a detecção e classificação de mudanças na cobertura e uso da terra é um tema em evidência e a cada dia surgem novas propostas e abordagens para diferentes objetivos. Essa tese tem por objetivo propor uma metodologia para o mapeamento de mudanças em coberturas florestais utilizando a abordagem baseada em objeto e apoiada em imagens Landsat TM. Foi escolhida como área de estudo a bacia hidrográfica do rio São João, localizada no estado do Rio de Janeiro, considerando uma série histórica de 27 anos com imagens dos anos de 1984, 1994, 2007 e 2011. O processo foi dividido em três etapas: a normalização das imagens da série histórica para compatibilizá-las e permitir sua comparação, a análise multitemporal para identificar as áreas de cobertura florestal que apresentaram algum tipo de mudança, e, por fim, as análises bitemporais para caracterizar os tipos de mudanças (Supressão e Regeneração) em cada intervalo da série. A exatidão temática da classificação multitemporal atingiu uma exatidão global de 95% e índice *kappa* de 0,9. As classificações bitemporais foram separadas nos intervalos de 1984-1994, 1994-2007 e 2007-2011, e apresentaram como exatidão global, respectivamente, de 85%, 87% e 85% e índice *kappa* de, respectivamente, 0,8; 0,83 e 0,8. Quanto aos resultados da classificação, na análise multitemporal foram encontrados 628 Km² de cobertura florestal inalterada (30% da área total da área de estudo) e 230 Km² de cobertura florestal (10% da área total da área de estudo) que apresentaram algum tipo de mudança na série histórica. A dinâmica da cobertura florestal na área apresentou uma diminuição ao longo da série, se estabilizando nos últimos anos. No período de 1984 até 1994 ocorreram 77 Km² de supressão e 33 Km² de regeneração da cobertura florestal. Já entre 1994 e 2007 foram 27 Km² de supressão e 13 Km² de regeneração, enquanto que entre 2007 e 2011 houveram 6 Km² de supressão e 16 Km² de regeneração.

Abstract

Land cover change detections techniques is a topic that has always been discussed and new methods and approaches are constantly being introduced with different objectives. The main goal of this thesis is to propose a forest cover change detection methodology using an object-based image analysis with Landsat TM data. The São João river basin, located at Rio de Janeiro State, was selected as study area and a 27 years' time series data was used to analyze the changes with images from 1984, 1994, 2007 and 2011 dates. The process was divided in three stages: time series images normalization for compatibilization and to allow for data comparison, multitemporal analysis to identify forest cover that has changed at any point within the time series, and bitemporal analysis to classify types of changes (suppression and regeneration) at each interval. Thematic accuracy was achieved for multitemporal classification with a 95% global accuracy and 0,9 Kappa index. Bitemporal classification was separated into three intervals: 1984-1994, 1994-2007 and 2007-2011 and achieved global accuracy of, respectively, 85%, 87% and 85% and Kappa index of, respectively, 0,8; 0,83 and 0,8. In respect of classification results, the multitemporal approach mapped 628 Km² (30% of total study area) of unchanged forest cover and 230 Km² (10% of total study area) of changed forest cover within the whole time series. The forest cover dynamic showed a decrease process during the time series, especially in recent years. Between 1984 and 1994, 77 Km² of forest cover was suppressed and 33Km² was regenerated. In the period of 1994 and 2007, 27 Km² of forest cover was suppressed and 13 Km² was regenerated, while between 2007 and 2011 only 6 Km² was suppressed and 16 Km² of forest cover regenerated.

LISTA DE FIGURAS

FIGURA 2.1- EXEMPLO DE PERFIL DE NDVI GERADO PELO SATVEG. (FONTE:WWW.SATVEG.CNPQIA.EMBRAPA.BR)	38
FIGURA 2.2- SISTEMA DE ALERTA DE SUPRESSÃO FLORESTAL GLAD NO SITE GLOBAL FOREST WATCH. (FONTE:WWW.GLOBALFORESTWATCH.ORG/MAP)	39
FIGURA 2.3- ÁREA MONITORADA PELO PROJETO OLHO NO VERDE (FONTE: SECRETARIA DE AMBIENTE DO RIO DE JANEIRO)	40
FIGURA 3.1- FLUXOGRAMA DA PROPOSTA METODOLÓGICA	41
FIGURA 3.2- ÁREA DE ESTUDO PILOTO, BACIA HIDROGRÁFICA DO RIO SÃO JOÃO	42
FIGURA 3.3- RELEVO, HIDROGRAFIA E CORPOS D'ÁGUA DA BHSJ	43
FIGURA 3.4- CENAS 216/76 DO SENSOR TM	45
FIGURA 3.5- PONTOS PSEUDOVARIANTES USADOS NO PROCESSO DE NORMALIZAÇÃO	47
FIGURA 3.6- FLUXOGRAMA DO PROCESSO DE NORMALIZAÇÃO	48
FIGURA 3.7- PARÂMETROS PARA O ALGORITMO MULTIREOLUTIONSEGMENTATION. (FONTE: ADPTADO E TRADUZIDO DE TRIMBLE, 2014)	49
FIGURA 3.8- COMPARAÇÃO DAS SEGMENTAÇÕES UTILIZANDO OS ALGORITMOSMULTIREOLUTIONSEGMENTATION (A) E O SPECTRALDIFFERENCE (B)	51
FIGURA 3.9- ÁRVORE DE DECISÃO DO MODELO DE CLASSIFICAÇÃO	52
FIGURA 3.10- EXEMPLO DO MODELO MULTITEMPORAL PARA COBERTURA FLORESTAL	53
FIGURA 3.11- EXEMPLO DO MODELO PARA CLASSIFICAÇÃO DE SUPRESSÃO NÃO FLORESTAL	56
FIGURA 4.1- MAPA COM AS MUDANÇAS E NÃO MUDANÇAS CONSIDERANDO A SÉRIE HISTÓRICA DE 1984 A 2011. DATUM: SIRGAS 2000	66
FIGURA 4.2- MAPA DE MUDANÇAS NA COBERTURA FLORESTAL ENTRE 1984 E 1994. DATUM: SIRGAS 2000	67
FIGURA 4.3- MAPA DE MUDANÇAS NA COBERTURA FLORESTAL ENTRE 1994 E 2007. DATUM: SIRGAS 2000	72
FIGURA 4.4- MAPA DE MUDANÇAS NA COBERTURA FLORESTAL ENTRE 2007 E 2011. DATUM: SIRGAS 2000	77
FIGURA 4.5- MAPA DAS TRAJETÓRIAS DE MUDANÇAS DE ACORDO COM O SALDO FINAL	84
FIGURA 4.6- MAPA COM OS TIPOS DE MUDANÇAS NA COBERTURA FLORESTAL AO LONGO DO TEMPO	86
FIGURA 7.1- ÁRVORE DE PROCESSO	103

Lista de Gráficos

GRÁFICO 4.1- AMOSTRAS DE FLORESTA NAS IMAGENS EM VALOR DE REFLECTÂNCIA	58
GRÁFICO 4.2- AMOSTRAS DE FLORESTA NAS IMAGENS NORMALIZADAS	59
GRÁFICO 4.3- AMOSTRAS DE GRAMÍNEA NAS IMAGENS EM VALOR DE REFLECTÂNCIA	60
GRÁFICO 4.4- AMOSTRAS DE GRAMÍNEA NAS IMAGENS NORMALIZADAS	60
GRÁFICO 4.5- AMOSTRAS DE SOLO EXPOSTO NAS IMAGENS EM VALOR DE REFLECTÂNCIA.....	61
GRÁFICO 4.6- AMOSTRAS DE SOLO EXPOSTO NAS IMAGENS NORMALIZADAS.....	61
GRÁFICO 4.7- ÁREA TOTAL (KM ²) DAS CLASSES SUPRESSÃO, REGENERÇÃO E MUDANÇAS NÃO FLORESTAIS ENTRE 1984 E 1994	68
GRÁFICO 4.8- NÚMERO DE OBJETOS POR CLASSES DE SUPRESSÃO, REGENERÇÃO E MUDANÇAS NÃO FLORESTAIS ENTRE 1984 E 1994	68
GRÁFICO 4.9- MÉDIA E DESVIO PADRÃO DAS ÁREAS(HECTARES) DOS OBJETOS ENTRE 1984 E 1994	69
GRÁFICO 4.10- - ÁREA E FREQUÊNCIA DE SUPRESSÃO POR CLASSE DE DECLIVIDADE ENTRE 1984-1994.....	70
GRÁFICO 4.11- - ÁREA E FREQUÊNCIA DE REGENERÇÃO POR CLASSE DE DECLIVIDADE ENTRE 1984-1994	70
GRÁFICO 4.12- ÁREAS DAS MUDANÇAS POR FAIXA DE ALTITUDE ENTRE 1984-1994	71
GRÁFICO 4.13- ÁREA TOTAL (KM ²) POR CLASSES DE SUPRESSÃO, REGENERÇÃO E MUDANÇAS NÃO FLORESTAIS ENTRE 1994 E 2007	73
GRÁFICO 4.14- NÚMERO DE OBJETOS POR CLASSES DE SUPRESSÃO, REGENERÇÃO E MUDANÇAS NÃO FLORESTAIS ENTRE 1994 E 2007	73
GRÁFICO 4.15- MÉDIA E DESVIO PADRÃO DAS ÁREAS (HECTARES) DOS OBJETOS ENTRE 1994 E 2007.....	74
GRÁFICO 4.16- ÁREA E FREQUÊNCIA DE SUPRESSÃO POR CLASSE DE DECLIVIDADE ENTRE 1994-2007	75
GRÁFICO 4.17- ÁREA E FREQUÊNCIA DE REGENERÇÃO POR CLASSE DE DECLIVIDADE ENTRE 1994-2007	75
GRÁFICO 4.18- ÁREA DAS MUDANÇAS POR FAIXA DE ALTITUDE ENTRE 1994-2007	76
GRÁFICO 4.19- ÁREA TOTAL (KM ²) POR CLASSE DE MUDANÇA 2007-2001.....	78
GRÁFICO 4.20- NÚMERO DE OBJETOS POR CLASSE DE MUDANÇA 2007-2011	78
GRÁFICO 4.21- MÉDIA E DESVIO PADRÃO DAS ÁREAS (HECTARES) DOS OBJETOS ENTRE 2007-2011	79
GRÁFICO 4.22-ÁREA E FREQUÊNCIA DE REGENERÇÃO NÃO FLORESTAL POR CLASSE DE DECLIVIDADE ENTRE 2007 E 2011	79
GRÁFICO 4.23- ÁREA E FREQUÊNCIA DE REGENERÇÃO POR CLASSE DE DECLIVIDADE ENTRE 2007 E 2011	80
GRÁFICO 4.24- ÁREA DAS MUDANÇAS POR FAIXA DE ALTITUDE ENTRE 2007 E 2011.....	80
GRÁFICO 4.25- SUPRESSÃO E REGENERÇÃO POR PERÍODO ANALISADO	81

GRÁFICO 7.1- GRÁFICOS NORMALIZAÇÃO 1984	98
GRÁFICO 7.2- GRÁFICOS NORMALIZAÇÃO 2007	99
GRÁFICO 7.3- GRÁFICOS NORMALIZAÇÃO 2011	100

Lista de Tabelas

TABELA 1- BANDAS ESPECTRAIS DOS SENSORES TM E SEUS COMPRIMENTOS(MICRÔMETRO)	44
TABELA 2- LIMIARES USADOS NO DESCRITOR DIFERENÇA DE SWIR2.....	55
TABELA 3-RESUMO DO ERRO MÉDIO QUADRÁTICO DO PROCESSO DE NORMALIZAÇÃO.....	57
TABELA 4- MATRIZ DE CONFUSÃO DAS CLASSES MUDANÇA E NÃO MUDANÇA NA COBERTURA FLORESTAL.....	62
TABELA 5- MATRIZ DE CONFUSÃO DO PERÍODO DE 1984 A1994	63
TABELA 6– ERROS DE OMISSÃO E COMISSÃO NO PERÍODO DE 1984 A 1994.....	63
TABELA 7- MATRIZ DE CONFUSÃO DO PERÍODO DE 1994 A 2007	64
TABELA 8– ERROS DE OMISSÃO E COMISSÃO NO PERÍODO DE 1994 A 2007.....	64
TABELA 9- MATRIZ DE CONFUSÃO DO PERÍODO DE 2007 A 2011	65
TABELA 10– ERROS DE OMISSÃO E COMISSÃO NO PERÍODO DE 2007 A 2011.....	65
TABELA 11- TRAJETÓRIAS DAS MUDANÇAS	83
TABELA 12- CATEGORIZAÇÃO DOS OBJETOS SEGUNDO CRITÉRIO DE MUDANÇA TEMPORAL.....	85
TABELA 13- TRAJETÓRIAS CONSIDERANDO MUDANÇAS NÃO FLORESTAIS	87
TABELA 14- TABELA DA TRAJETÓRIA DETALHADA	101

Lista de Siglas

APP	Área de Proteção Permanente
DETER	Detecção de desmatamento em tempo real
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GCP	<i>GroundControl Point</i> (Ponto de Controle no Terreno)
GEOBIA	<i>Geographic-Object-BasedImageAnalysis</i> (Análise de imagem baseada em objetos geográficos)
GLAD	<i>Global Land Analysis & Discovery</i>
GLCM	<i>Gray level co-occurrence matrix</i>
GS	Gramm-Schmidt
INEA	Instituto Estadual do Ambiente
INPE	Instituto Nacional de Pesquisas Espaciais
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
LIDAR	<i>Light Detection And Ranging</i>
MDE	Modelo Digital de Elevação
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NASA	<i>National Aeronautic and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>NearInfra-Red</i> (Infravermelho Próximo)
OBCD	<i>Object-Based Change Detection</i> (Detecção de mudança baseado em objeto)
PCA	<i>Principal Component Analysis</i> (Análise de principais componentes)

PIF	<i>Pseudo-Invariant Features</i> (Pontos pseudoinvariantes)
RMS	<i>Root Mean Square</i> (Erro Médio Quadrático)
SIG	Sistemas de Informação Geográfica
SWIR	<i>ShortwaveInfra-red</i> (Infravermelho de ondas curtas)
TM	<i>Thematic Mapper</i>
TOA	<i>Top of Atmosphere</i> (Topo da Atmosfera)
SATVEG	Sistema de Análise Temporal da Vegetação
VANT	Veículo Aéreo Não Tripulado
USGS	<i>United States Geological Survey</i>

Sumário

1.	INTRODUÇÃO	14
1.1.	OBJETIVOS E ESTRUTURA DA TESE	15
2.	REVISÃO CONCEITUAL	17
2.1.	A SEMÂNTICA DO USO E COBERTURA DA TERRA, SUAS REPRESENTAÇÕES E DINÂMICAS.....	17
2.2.	BREVE HISTÓRICO SOBRE ESTUDOS RELACIONADOS À MUDANÇA NO USO DA TERRA	19
–	<i>Período pré-industrial</i>	19
–	<i>Primeira metade do século XX</i>	20
–	<i>Segunda metade do século XX</i>	21
2.3.	TÉCNICAS DE CLASSIFICAÇÃO DE IMAGENS DIGITAIS	24
2.4.	TÉCNICAS DE DETECÇÃO DE MUDANÇA DE USO E COBERTURA DA TERRA	27
–	<i>Objetos (Image-object)</i>	32
–	<i>Classe do objeto</i>	33
–	<i>Objetos multitemporais</i>	35
–	<i>Híbrido</i>	36
2.5.	EXEMPLOS DE PROJETOS DE ANÁLISE DE MUDANÇAS EM COBERTURAS VEGETAIS	37
3.	CONTRIBUIÇÃO METODOLÓGICA PARA DETECÇÃO DE MUDANÇAS EM COBERTURA FLORESTAL ..	41
3.1.	ÁREAS DE ESTUDO	42
3.2.	MATERIAIS E PROCESSAMENTO DIGITAL DE IMAGENS.....	43
3.3.	MODELAGEM E CLASSIFICAÇÃO	51
4.	ANÁLISE DOS RESULTADOS	57
4.1.	QUANTO À NORMALIZAÇÃO	57
4.2.	QUANTO À EXATIDÃO TEMÁTICA	61
4.3.	QUANTO À CLASSIFICAÇÃO	65
4.3.1.	POR INTERVALO	66
4.3.1.1.	DE 1984 A 1994.....	67
4.3.1.2.	1994-2007	71
4.3.1.3.	2007 A 2011	76
4.3.2.	PELA TRAJETÓRIA	81
4.3.2.1.	CRITÉRIO SIMPLIFICADO	82
4.3.2.2.	CRITÉRIO DETALHADO	86
5.	CONSIDERAÇÕES FINAIS	89

5.1.	QUANTO AO MÉTODO.....	89
5.2.	QUANTO AOS RESULTADOS	89
5.3.	PERSPECTIVAS FUTURAS.....	90
6.	REFERÊNCIAS	92
7.	ANEXOS	98
	GRÁFICOS DE NORMALIZAÇÃO	98
	TABELA DA TRAJETÓRIA DETALHADA.....	101
	ÁRVORE DE PROCESSO.....	103

1. Introdução

O entendimento de como a humanidade interage, ocupa, se adapta e modifica o meio no qual está inserida sempre foi de interesse dos estudos geográficos. As transformações na superfície terrestre, sob diferentes perspectivas ao longo do desenvolvimento da Ciência, são os principais motivadores para as pesquisas em Geografia. Uma das formas mais elementares de leitura da superfície terrestre é através de mapas de cobertura e uso da terra, que oferecem informações dos elementos e contexto da área de interesse. Este instrumento se tornou um requisito essencial para o planejamento e gestão territorial em diferentes níveis, fornecendo informações para tomadas de decisão e organização do espaço. Com o advento das técnicas de sensoriamento remoto e a disponibilidade de imagens orbitais e aéreas houve um grande aumento na produção desse tipo de mapeamento. Isto viabilizou o incremento de estudos focados nos processos de mudanças da superfície terrestre conhecidos como *change detection* e definido por Singh (1989) como "o processo de identificação do estado do objeto ou fenômeno através da observação em diferentes momentos". Diferentemente da maioria dos mapas temáticos, não existe um especialista próprio para elaboração de mapas de cobertura e uso, pois este produto atende a um público que vai de ramos variados da pesquisa científica a instituições públicas e privadas, sendo produzidos por pessoas com formações e propósitos distintos, levando à falta de padronização de legenda e escala. Dessa forma, a integração desses mapas para uma análise de mudança de uso e cobertura torna-se uma tarefa difícil, pois o cruzamento de mapas com diferentes datas para identificação dos tipos de mudança só apresenta resultados consistentes quando estes são elaborados dentro de uma mesma metodologia e padrão cartográfico. Esta dificuldade cria o desafio de desenvolver metodologias alternativas para detecção e classificação desses fenômenos, o que faz a comunidade científica se debruçar sobre a temática.

O debate sobre a construção de diferentes metodologias para detecção e classificação de mudanças na cobertura e uso da terra é um tema em evidência e a cada dia surgem novas propostas e abordagens para diferentes objetivos. Algumas vezes, a rápida evolução em termos de técnicas de aquisição e de tipos de sensores não é compatível com o tempo necessário para a incorporação dessas inovações nas metodologias já consagradas. Ou seja, as inovações técnicas podem ser mais rápidas e constantes do que as inovações metodológicas de aplicação. Essa questão é muito

evidente quando se discute dinâmica de cobertura e uso da terra. Existe grande demanda por parte dos tomadores de decisão em obter essas informações para auxiliar na resolução de questões problemáticas referentes a planejamento, gestão, conflitos ambientais, fiscalização etc. Ressalta-se que cada vez mais essas informações precisam ser apresentadas o mais detalhadamente possível e com alta acurácia, pois elas influenciarão medidas que afetam todas as camadas da sociedade, como definição de zoneamentos ambientais e econômicos, critérios do ICMS ecológico etc. No cenário atual encontramos fontes de dados para alcançar essa exigência, porém, devido à carência de métodos que possam ser aplicados de forma sistemática e ágil, existe uma limitação no aproveitamento das informações. Com isso, é importante o investimento no desenvolvimento de novas metodologias que visem uma maior agilidade e praticidade no processo de detecção e classificação de mudanças da superfície terrestre de modo a atender usuários que não são, necessariamente, da área acadêmica, tais como os responsáveis pelas decisões a serem tomadas em instituições públicas ou privadas.

1.1. Objetivos e estrutura da tese

Pelo fato da abordagem baseada em objeto ter sido desenvolvida para atender a imagens de alta resolução, ainda se faz necessário investigar a potencialidade de aplicação em imagens de média e baixa resolução, cuja importância para países de grandes extensões territoriais é notória. Sendo assim, pretende-se desenvolver um método para análise de mudanças florestais em mesoescala que busque aproveitar as vantagens dos métodos baseados em *pixel* já adotados para esse tipo de imagem (LU, MAUSEL, *et al.*, 2004; SINGH, 1989; SONG, WOODCOCK, *et al.*, 2001) em uma abordagem baseada em objetos, de um modo simples e de fácil execução.

Esta tese tem por objetivo contribuir metodologicamente para o mapeamento de mudanças em coberturas florestais utilizando a abordagem baseada em objeto apoiado em imagens Landsat, uma vez que esse tipo de técnica vem demonstrando bons resultados e grande potencial para inovações. Para isso, será necessário buscar:

- Avaliar métodos de pré-processamento digital em apoio a estudos de detecção de mudanças, minimizando diferenças provenientes de condições diferenciadas de aquisição.

- Desenvolver um método de classificação de mudanças em uma área teste localizada na Bacia Hidrográfica do Rio São João, RJ.

A tese se divide em cinco capítulos: o primeiro introduzirá a temática da tese, com a definição dos objetivos, justificativa; o segundo apresentará a revisão conceitual de assuntos pertinentes ao tema da tese; o terceiro demonstrará a construção da metodologia proposta a partir de um estudo na Bacia Hidrográfica do Rio São João (BHRSJ); o quarto capítulo apresentará como foram realizadas as análises dos resultados da detecção de mudança. No quinto e último capítulo serão feitas as considerações finais da pesquisa realizada.

2. Revisão Conceitual

2.1. A semântica do uso e cobertura da terra, suas representações e dinâmicas

Os conceitos de uso e cobertura da terra são simples e podem ser compreendidos praticamente de modo dedutivo. A definição literal das palavras cobertura e uso já expressa, em boa parte, o sentido do conceito. A palavra uso, derivada do verbo ‘usar’, traz consigo a ideia de imprimir ação sobre algo, enquanto cobertura remete a algo concreto. A cobertura tem como característica ser algo físico, a superfície terrestre propriamente dita. Para Turner et al (1995), a cobertura da terra é o estado biofísico da superfície e subsuperfície da terra. Já o termo uso envolve um valor atribuído pelo homem a uma determinada área ou a uma atividade econômica, sua noção é mais subjetiva e não é tão materializável como a cobertura. Está relacionado à cultura humana, em como um indivíduo ou um grupo se apropria da terra e a utiliza. Para Skole (1994), o uso da terra é o modo que o homem emprega alguma atividade em um tipo de cobertura, e este modo é determinado por fatores sociais complexos. A diferença entre eles é destacada em diversos documentos de classificação (ANDERSON, HARDY, *et al.*, 1976; DI GREGORIO e JANSEN, 2000; IBGE, 2013). Os conceitos de uso e cobertura geralmente são apresentados juntos, pois possuem uma relação de complementaridade e estão sobrepostos espacialmente, isto é, um determinado local sempre possuirá um tipo de cobertura e um ou mais tipos de usos. Porém, esta sobreposição não é fixa, um tipo de cobertura pode ter diferentes usos, assim como um determinado uso pode estar associado a mais de uma cobertura. Fischer et al (2005) ressaltam que a representação do uso e cobertura juntos podem acarretar incompatibilidade de integração e comparação entre diferentes fontes, pois, muitas vezes, as distinções entre cobertura e uso não são claras e os propósitos para qual foram estabelecidas são distintos.

A maneira mais recorrente de representação da cobertura e uso da terra é na forma de mapa, situado em recortes espacial e temporal previamente estabelecidos pelos interesses do produtor ou usuário da informação. Menezes e Fernandes (2013) afirmam que o mapa deve ser um modelo que permita conhecer a estrutura do fenômeno que está sendo representado. A cobertura da terra, diferente do uso, tem suas representações elaboradas de forma mais fácil por se tratar de um aspecto físico e de observação direta. Inicialmente essas observações eram feitas *in loco* ou a partir da visão oblíqua, em alguma localidade onde fosse possível ter uma vista panorâmica da área de interesse. Com o desenvolvimento da fotogrametria aérea e, posteriormente do sensoriamento remoto orbital,

os estudos que focavam a cobertura da terra tiveram um grande impulso devido a visão ortogonal, que facilitou a capacidade de se analisar vastas áreas. O aumento constante da disponibilidade de imagens com diferentes características, com variadas resoluções espaciais, temporais e espectrais, permitiu estudos em diferentes escalas. Essa evolução técnica permitiu significativos avanços nas formas de representar as características físicas da cobertura da superfície terrestre, porém, essa especialização acabou, por vezes, negligenciando outros aspectos relativos aos usos e ações humanas. A partir da cobertura pode se tentar inferir alguns aspectos do tipo de uso relacionado e, apesar dessa relação não ser direta, ajuda a uma melhor contextualização dos fenômenos de interesse, porém, a cobertura por si só não é suficiente para compreender o uso de maneira aprofundada.

Geralmente, os mapas de cobertura e uso da terra representam um instante no tempo, sintetizando, simplificando e realçando as informações daquela(s) data(s). É importante salientar que o uso e cobertura se modificam ao longo do tempo, podendo ser mais ou menos dinâmicos dependendo de inúmeros fatores. As transformações que ocorrem ao longo do tempo no uso e cobertura também expõem a relação de complementaridade entre eles. Nesse caso, analisar e representar essas mudanças são um desafio, uma vez que requerem trabalhar com mais de um momento e diferentes abordagens. A questão temporal é importante, pois a natureza das mudanças que ocorrem no uso e cobertura da terra variam de intensidade e frequência e, dependendo do que está sendo investigado, diferentes recortes devem ser escolhidos. Na maioria das vezes as mudanças no uso são responsáveis pelas mudanças na cobertura através das atividades humanas que são influenciadas por diferentes fatores.

Atualmente, com o acúmulo de mais de quarenta anos de imageamento, como é o caso das imagens Landsat, é possível usar um recurso conhecido como *time lapse*. A partir de uma sequência de imagens de diferentes datas de um mesmo local é feita uma animação usando as diferentes aquisições como se fossem *frames* de um filme. Dessa forma é possível perceber as mudanças ocorridas durante o intervalo de tempo disponível. Muda-se de uma visão estática da área para a percepção dos movimentos dos objetos presentes nas imagens, facilitando a interpretação das mudanças ocorridas naquele espaço. Esse recurso tem sido aplicado não só com imagens aéreas, mas também com fotografias sob pontos de vista de diferentes lugares, seja para observar o trajeto do pôr do sol ou entender a dinâmica de uma determinada área de um centro urbano. Muitas vezes

essa técnica é usada para monitoramento de grandes obras de intervenção urbana, de modo que é possível acompanhar o andamento de acordo com o cronograma, e ter um maior controle. É um recurso que amplia as maneiras de se interpretar a dinâmica dos fenômenos e pode ser usado nos estudos de mudança de uso e cobertura. O princípio do *time lapse* também pode ser usado com outras fontes de informação, como dados provenientes de diversos *sites* na internet, como os de tráfego urbano, as variações das marés, câmeras de monitoramento, previsão do tempo etc.

2.2. Breve histórico sobre estudos relacionados à mudança no uso da terra

Segundo Briassoulis (2000), os estudos entre os séculos XIX e XX que abordam, direta ou indiretamente, a temática de mudança no uso da terra pode ser dividida em três períodos: pré-industrial, que seria até a virada do século, a primeira metade do século XX e a segunda metade do século XX.

– Período pré-industrial

Dois trabalhos marcantes para os estudos de dinâmica de uso da terra durante o século XIX foram de George Perkins Marsh (1864) e Johann Heinrich von Thunen (1826). Marsh, um diplomata norte-americano que passou boa parte de sua vida trabalhando com relações internacionais, publicou no final de sua vida o livro *Man and Nature*(1864), que trata da magnitude e extensão dos impactos provocados pelas ações do homem ao redor do mundo. A partir de descrições detalhadas, o autor tenta explicar as transformações ambientais observadas e sugerir como o homem deve se posicionar ao interagir com a natureza. Para muitos ele pode ser considerado o primeiro conservacionista da história. A questão dos diferentes tipos de uso da terra é implícita em seu trabalho, onde toda atividade humana é localizada e modifica o espaço para determinados fins.

Já J.H.vonThunen, um economista alemão proprietário de terra, teve como principal questão a determinação da melhor configuração espacial de suas lavouras e outras atividades, de modo que essa disposição fosse o mais eficiente possível em termos de custo e benefício. Desta forma, desenvolveu um modelo geral de como as atividades rurais deveriam se dispor em relação ao mercado principal. A partir de pressupostos bem generalistas como uniformidade espacial, somente um centro de mercado, concorrência perfeita e um tipo de transporte, chegou a conclusão

que a eficiência da disposição de um determinado uso é dependente da distância do mercado. Ele via a terra como um recurso econômico de acordo com seu potencial de produtividade.

Estes dois pensadores expressaram pela primeira vez duas abordagens sobre mudanças no uso da terra extremamente opostas que, apesar de não declararem explicitamente esse conceito, serviram de referência para a sequência de estudos das décadas seguintes que transitaram entre esses dois polos. O legado de Marsh e von Thunen marcou essas duas correntes opostas, onde toda a teorização e modelagem de mudança de uso da terra que se desenvolveu ao longo do século XX transitou entre esses dois extremos. A visão de Marsh sobre a terra e o papel do homem nas alterações do ambiente natural foi a base de uma série de teorias e modelos integrados sobre sociedade-natureza que surgiram nos anos seguintes, e que ainda estão em presente na atualidade, enquanto o viés econômico de von Thunen, que privilegiava uma produção racional de bens em uma paisagem uniforme e estática, fundou as principais teorias e modelos de economia regional e urbana do século XX.

Há de considerar que nesse mesmo contexto histórico também está presente a consolidação do conceito de evolução proposto por Charles Darwin (1859), que passou a ter grande influência sobre diversas áreas da ciência. A ideia de mudança, ou transformação, passa a ganhar mais destaque e importância nos fenômenos estudados, o que de certa forma estimula ainda mais a reflexão sobre a dinâmica de uso da terra pelo homem.

– Primeira metade do século XX

Na civilização ocidental, os primeiros anos do século XX foram marcados por intensas mudanças no uso da terra, influenciadas principalmente, pelo processo de urbanização, industrialização e avanços tecnológicos. No âmbito da ciência, a revolução quantitativa ganhava força na maioria dos campos. Os estudos que documentaram as mudanças de uso da terra tinham como característica o estabelecimento de uma análise sistemática e "científica" baseada em teorias e modelos de diferentes campos da ciência (Economia, Sociologia, Geografia etc.). Isto é reflexo da emergência e dominância da forma de teorizar e modelar sobre os usos da terra de diferentes campos das ciências sociais durante este período.

A Teoria dos lugares centrais desenvolvida por Christaller em 1933 propôs uma base teórica para explicar o tamanho e a distribuição de estabelecimentos comerciais em uma área urbana a

partir de dois conceitos principais: alcance e limiar. Em 1940, Losch utilizou essa base conceitual e aprofundou os padrões de lugares centrais, considerando outras funções urbanas além de estabelecimentos comerciais. O padrão hierárquico hexagonal dos lugares é uma característica dessas duas versões da teoria. Vale notar que a preocupação principal dessas teorias era a localização espacial de determinados tipos de uso da terra, e não o uso da terra em si.

No campo da Sociologia, o desenvolvimento da Ecologia Humana pela escola de Chicago nos anos 1920 teve impacto nas análises das estruturas de uso da terra e de mudanças em regiões urbanas dos períodos que seguiram. Nesta lógica, conceitos da Ecologia como comunidade, competição, invasão, equilíbrio, clímax etc. foram usados para descrever e explicar padrões observados em áreas urbanas, assim como os processos sociais e econômicos subjacentes.

As teorias apresentadas têm em comum a abordagem funcionalista, onde se procura por repetições e regularidades previsíveis, em que forma e função podem ser assumidamente relacionadas. A ecologia humana tem uma abordagem mais descritiva, enquanto a teoria de lugares centrais é mais normativa e prescritiva. A terra, ou espaço de uma forma geral, não possui propriedades intrínsecas, é abstrata e amórfica. As atividades humanas e os usos da terra associados a elas são tratadas como se elas não ocorressem de forma extensiva no espaço, e sim como pontos em um mapa. O foco é a sua localização e os padrões resultantes desse arranjo. As mudanças no uso da terra seriam apenas uma resposta mecânica e previsível da mudança de distância ou custo de transporte, uma consequência natural dessa abordagem funcionalista (BRIASSOULIS, 2000).

– Segunda metade do século XX

As análises científicas sobre mudanças de uso da terra tiveram um aumento significativo após a segunda guerra mundial, dando continuidade a muitas linhas utilizadas até então. A diversidade de temas se multiplicou nas escalas locais, regionais e globais. As abordagens passaram a adotar ramos da geografia, economia, sociologia e das ciências naturais, e um caráter interdisciplinar começou a ganhar força a partir da década de 1970. A proliferação dos estudos e as direções que as propostas tomaram também estavam relacionados ao contexto das mudanças teóricas e metodológicas vividas nessa época. A chamada revolução quantitativa atingiu a maioria das disciplinas entre 1950 e 1960, mas os modelos formais e as teorias propostas por essa corrente foram rejeitadas e criticadas mais tarde em função de suas limitações e questionamentos de suas

fundações epistemológicas. Paralelamente, a evolução técnica computacional e de processamento de dados estimulava a orientação quantitativa em muitos estudos pela capacidade de executar tarefas antes inviáveis. Porém, também se buscava abordagens qualitativas e heurísticas, não limitadas pelos rígidos e simples pressupostos da teoria quantitativa inicial. Um outro fator que influenciou modificações na perspectiva epistemológica dos estudos de mudanças no uso da terra foi o recente interesse político nas implicações negativas resultantes das mudanças ambientais globais. Dessa forma, a demanda por informação de cunho prático e de suporte para nortear os tomadores de decisões de políticas públicas passou a ser temas frequentes em linha de estudos relacionados ao uso da terra. Nem sempre a mudança de uso da terra era o objeto de análise principal, e sim outros aspectos e dimensões das mudanças espaciais, embora houvesse, na maioria das vezes, uma ligação direta ou indireta. Nota-se, também, um aumento dos estudos sobre mudança no uso da terra em áreas particulares das ciências naturais e aplicadas, como agronomia, biologia, sensoriamento remoto etc.

Também foi dado continuidade nos estudos de estrutura espacial regional e urbana. A maioria dos que se relacionavam explicitamente com mudanças de uso da terra eram os que tratavam da questão urbana/intraurbana, analisando os usos residenciais, comerciais, de transporte etc. Diversas variantes dos modelos clássicos, como Christaller (1966) e Alonso (1964), surgiram com a intenção de flexibilizar seus pressupostos e acrescentar novos, que fossem mais coerentes com o comportamento econômico espacial. A análise das mudanças de uso da terra sob a ótica econômica tem como característica a ênfase no preço dos mecanismos (terra e custo de transporte) como principal determinante para a locação de atividades humanas no espaço. São abordagens funcionalistas, quantitativas e as vezes altamente matemáticas baseadas em pressupostos que dizem respeito à terra, seu uso e mudanças, assim como as preferências e características de seus usuários.

No campo mais amplo da sociologia que lidava com mudanças no uso da terra, duas abordagens particulares se desenvolveram: a comportamental e institucional. A primeira tenta descrever e explicar padrões de uso da terra como uma função de fatores que influenciam o comportamento humano e as tomadas de decisão, focando nas atividades humanas. O segundo, conhecido também com estruturalismo, enfatiza as restrições impostas ao comportamento humano pelas instituições da sociedade para explicar os padrões espaciais urbanos e de outras áreas (BRIASSOULIS, 2000). Os conceitos centrais dessa abordagem são poder e conflito, geralmente

por conta das desigualdades ou diferenças de classes. Essas duas abordagens fazem parte de um longo repertório desenvolvido nos anos 1970 que faziam oposição ao empirismo e positivismo, e eram influenciados pela teoria social. Uma característica geral dessas linhas é lidar de uma maneira ou de outra, com espaço, estrutura espacial e relações sociais/espaciais, e tratar o espaço e assuntos humanos que ocorrem nele e interação com ele, de uma maneira abstrata.

Além das vertentes econômicas e sociais, uma série de outras abordagens voltadas para o estudo do uso da terra e suas mudanças foram influenciadas por ideias desenvolvidas na segunda metade do século XX. Elas combinaram elementos das ciências naturais e sociais e se basearam na noção de equilíbrio ecológico, que atribui as mudanças em uma região à interação dinâmica de quatro fatores: população, recursos, tecnologia e instituição (MEYER e TURNER, 1996).

Abordagens teóricas baseadas em ecossistemas e modelos que buscavam integrar meio ambiente, sociedade e economia passaram a ser difundidas após os anos 1970. O assunto mudança no uso da terra passou a ser reconhecido como um importante elemento do sistema sociedade-natureza com estreita relação com as mudanças ambientais globais, cujo estudo se tornou pré-requisito para a tomada de ações. O que diferencia essa abordagem das demais é o tratamento dado ao uso da terra e sua dinâmica considerando suas propriedades ambientais intrínsecas, seus atributos e capacidade de influenciar e ser influenciado pelas atividades e ações humanas. Sendo assim, a mudança de uso da terra é analisada a partir de uma configuração de interações entre sociedade e natureza, o que parece ser mais promissor para lidar com questões relacionadas à tomada de decisões e políticas de maneira integrada do que de forma unidimensional.

Além dos estudos teóricos e metodológicos, uma série de estudos empíricos vem sendo elaborados em diferentes escalas para identificar e registrar variados tipos de usos da terra e suas dinâmicas, principalmente aqueles que levam a impactos negativos ecológicos ou econômicos. Segundo o *Land Use and Cover Change Implementation Strategy*, uma iniciativa dos anos 1990 de se estudar mais a fundo as mudanças de uso e cobertura a nível global, existem três abordagens para a análise de mudanças baseadas em: narrativas, agentes e em sistemas. A narrativa visa um entendimento profundo através da interpretação detalhada dos acontecimentos. Conta a história das mudanças provendo uma base empírica e interpretativa, sendo eficiente em identificar eventos estocásticos e aleatórios que influenciam determinados tipos de mudanças. Já a baseada em agentes e em sistemas necessitam de um modelo explícito desenvolvido a partir de testes empíricos. O

primeiro tem como perspectiva central a significância dada aos agentes humanos em determinarem tipos de uso da terra e buscam uma generalização sobre esse comportamento. A abordagem baseada em sistemas procura entender, através da organização das instituições das sociedades, o estabelecimento de oportunidades e restrições nas tomadas de decisões. Meyer e Turner (1994) fornecem relatos históricos de estudos globais e apresentam as tendências atuais nessa perspectiva. Além dessas análises globais, outros estudos em escalas maiores também vêm fornecendo informações que ajudam a subsidiar tomadas de decisões políticas e direcionamento de pesquisas.

O desenvolvimento tecnológico nas áreas de gerenciamento de dados espaciais e sensoriamento remoto vem estimulando grandes projetos de observação e monitoramento do uso da terra. Além do que, facilitam o armazenamento e processamento de dados para o uso em diferentes contextos como pesquisa científica, elaboração de políticas públicas ou implementação de programas específicos (LIVERMAN, MORAN, *et al.*, 1998). Dessa forma, as principais fontes de dados passam a ser imagens digitais provenientes desse desenvolvimento tecnológico, e a manipulação desse tipo de informação se torna essencial para estudos nessa temática.

2.3. Técnicas de classificação de imagens digitais

Atualmente, é importante compreender a base das técnicas de classificação de imagens digitais, pois elas provêm as ferramentas necessárias para a execução de mapeamentos dentro deste novo paradigma digital. A diversidade de alvos a serem mapeados e os diferentes propósitos para tal se relacionam com as resoluções associadas aos sensores: espacial, que auxilia na identificação de alvos de diferentes tamanhos e formas; espectral, que permite a diferenciação de superfícies pela sua assinatura espectral; radiométrica, que possibilita a percepção de variações totais de refletância ou emitância da superfície terrestre, auxiliando na diferenciação de alvos; e a temporal, que está relacionada com a periodicidade da aquisição de uma determinada área pelo sensor.

Por muitos anos as imagens usadas para mapeamento eram adquiridas de forma analógica através de filmes fotográficos que eram revelados em papel. A partir da interpretação visual, o processo de extração da informação era feito manualmente, o que tomava bastante tempo e dependia de um intérprete experiente e com habilidades gráficas. Com a transição para aquisição de imagens digitais ampliou-se as possibilidades dos métodos de classificação. O formato digital tem sua estrutura baseada em uma matriz composta por *pixels*, que é o menor elemento de uma

imagem digital. O *pixel* armazena um valor numérico que corresponde ao nível de refletância de uma determinada área, quanto maior a refletância maior o valor. Este número pode ser associado a um tom de cinza ou a um canal de cor, o que faz com que a matriz de *pixel* possa ser visualizada como uma imagem ou uma tabela. A partir do entendimento da imagem como uma matriz numérica é possível aplicar uma série de modelos matemáticos para extrair diferentes tipos de informação. A interpretação visual e o conhecimento da área de estudo ainda são essenciais ao se trabalhar com imagens digitais, porém esses novos recursos trazem maior agilidade na produção, permitindo atuar em grandes áreas, com maior eficiência em um tempo que antes era inviável.

A classificação de imagens digitais pode ser dividida em dois grandes grupos: supervisionada e não supervisionada. Na supervisionada há uma definição prévia da legenda a ser utilizada e a partir da seleção de amostras na imagem, que servirão de base para elaboração de assinaturas espectrais, ou modelagem a partir do conhecimento das características do fenômeno a ser mapeado, algoritmos específicos são executados para a diferenciação de classes. Enquanto na não supervisionada o próprio algoritmo define a diferenciação em grupos, denominados *clusters*, cujos limiares de separação são definidos automaticamente. O usuário pode, posteriormente, relacionar esses agrupamentos a uma legenda definida. A classificação não supervisionada pode ser utilizada quando não se tem familiaridade com a área a ser classificada e precisa se de uma ideia preliminar sobre a variação das classes, enquanto que na supervisionada, normalmente, se tem mais segurança e conhecimento sobre a distribuição das classes. Além disso, nos dois casos é possível ter abordagens baseadas em *pixel*, regiões homogêneas ou objetos.

Inicialmente a classificação digital se restringia a uma abordagem baseada em *pixel*, isto é, que utiliza apenas as informações dos valores de cada *pixel* para encontrar regiões homogêneas através do uso de algoritmos classificadores. Um dos principais algoritmos utilizados neste tipo de classificação é conhecido como Kmedia, que é baseado no trabalho de Macqueen (1979) e objetiva particionar n observações em k grupos onde cada observação passa a pertencer ao grupo mais semelhante. Há também os algoritmos que se baseiam na máxima verossimilhança como o MAXVER, que considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos (CAMARA, SOUZA, *et al.*, 1996). Existe uma série de algoritmos desenvolvidos voltados para classificação baseada em *pixel* (LI, WANG, *et al.*, 2014).

Este tipo de recurso é de simples aplicação e não necessita de uma estrutura computacional robusta, o que ajudou na sua disseminação.

Com o melhoramento da capacidade de processamento de dados digitais desenvolveu-se a técnica de classificação baseada em regiões homogêneas, onde as imagens passam pelo processo de segmentação antes de serem classificadas. Este processo consiste na divisão das imagens em diversos segmentos através da definição de limiares de área mínima e similaridade entre *pixels* vizinhos (CAMARA, SOUZA, *et al.*, 1996). Com isso, a unidade mínima de análise passa a ser esses segmentos e não mais o *pixel*, o que permite que o resultado final não sofra a influência de pequenos ruídos comuns à classificação baseada em *pixels*. A etapa de segmentação ainda é crucial para a classificação e apesar dessa técnica ter sido desenvolvida inicialmente para outros tipos de aplicações (industriais), ela foi incorporada e adaptada para o uso em sensoriamento remoto terrestre (BLASCHKE, 2004). Em um primeiro momento, eram utilizadas informações simples desses segmentos, como a média dos valores dos *pixels*, e aplicava-se os mesmos algoritmos das técnicas baseadas em *pixel*.

Esse tipo de classificação acabou evoluindo para um método mais complexo, que não depende exclusivamente da assinatura espectral dos alvos, mas considera diversos aspectos de reconhecimento, como forma, textura, contexto, entre outras, conhecido como abordagem baseada em objetos geográficos ou GEOBIA (HAY e CASTILLA, 2008). Esta abordagem busca simular a interpretação visual adotando diferentes elementos cognitivos e, assim, tentar compreender os segmentos como objetos geográficos dotados de informações que vão além da simples resposta espectral. A partir desses objetos é possível extrair informações contextuais relacionadas à vizinhança entre eles, suas contiguidades e tamanho, além dos conjuntos de *pixels*, tais como média, desvio padrão, moda etc. Além disso, esta abordagem permite trabalhar com mais de um nível de segmentação estruturados de maneira hierárquica, sendo possível ter um nível de segmentação superior, mais grosseiro, com segmentos maiores e mais generalistas, e logo abaixo uma ou mais segmentações de maior detalhe, onde os segmentos maiores são subdivididos respeitando-se os limites do nível superior. A relação hierárquica garante a herança entre os segmentos de diferentes níveis. Este mesmo princípio se aplica à classificação, com uma legenda estruturada de forma hierárquica, como uma rede semântica, onde os diferentes níveis de hierarquia de classes herdam suas características estabelecendo diferentes detalhamentos da classificação.

Outro aspecto interessante, se tratando de uma classificação supervisionada baseada em objetos, é a possibilidade de se criar modelos individualizados por classes a partir das amostras. Estes modelos podem ser booleanos ou *fuzzy*, onde os primeiros têm um caráter discreto, estabelecendo um limite claro e determinístico entre o que está dentro e fora do modelo; e o segundo trabalha com graus de incerteza, definindo o que está dentro ou fora do modelo através de graus de pertinência. Dessa forma, é possível obter diferentes resultados de classificação a partir das mesmas amostras, pois este ambiente interativo de modelagem dá ao usuário uma flexibilidade de manipulação dos modelos de acordo com suas necessidades. A classificação baseada em objeto não vem para substituir a abordagem em *pixel*, ela pode ser vista como uma evolução do processo de classificação que surge para atender a questões que surgem com análises em grandes escalas utilizando imagens de alta resolução espacial. Muito dos algoritmos usados são uma transposição direta da abordagem baseada em *pixel*, que é possível apenas devido às atuais condições de processamento digital. Ambas as abordagens podem ser usadas de forma complementar em um mesmo processo de classificação, conhecido como processo híbrido.

As formas de classificação apresentadas são a atual estrutura para elaboração de uma variedade de métodos voltados para diferentes aplicações. A combinação de diferentes algoritmos com diferentes lógicas de processo de classificação resulta em uma variedade grande de métodos. Essa é uma área fértil para a inovação metodológica que está em constante construção. Na temática de análise de mudanças de uso e cobertura da terra, a literatura apresenta diversas metodologias que usam essas formas de diferentes maneiras.

2.4. Técnicas de detecção de mudança de uso e cobertura da terra

O mapa de uso e cobertura está sempre ancorado a uma data específica, representado de forma estática, como uma fotografia de um determinado momento. Para estudos relacionados à dinâmica de uso e cobertura da terra se faz necessário dois ou mais mapas ou imagens para a identificação e classificação das mudanças. Uma forma simples é a comparação de dois momentos distintos, geralmente referentes ao estado presente e outro momento pretérito, podendo perceber assim, as mudanças ocorridas ao longo deste intervalo de tempo de forma bitemporal. Quando se tem uma série histórica, com pelo menos mais de dois momentos, faz-se uma análise da dinâmica das mudanças de cobertura e uso de forma multitemporal, reconstituindo a evolução das transformações ocorridas na paisagem. E há uma terceira maneira, que está ligada ao âmbito do

monitoramento. Neste caso, a partir de uma série histórica ou não, é feita uma atualização constante do estado da cobertura e do uso da terra em intervalos determinados. É um procedimento que visa acompanhar as mudanças em andamento, através de sucessivos mapeamentos. Em cada tipo de análise serão encontrados resultados correspondentes ao nível temporal de observação, que é definido de acordo com o fenômeno que se propõe estudar.

Neste sentido, é possível perceber esforços da comunidade científica em desenvolver metodologias que busquem facilitar e melhorar as análises de mudanças de uso e cobertura da terra em múltiplas escalas espaciais e temporais. A diversidade de causas e relações que resultam em mudanças nos tipos de uso e cobertura da terra se apresentam de forma complexa e interligada, tornando essa tarefa ainda mais difícil.

Assim como na classificação digital tradicional, os métodos de detecção de mudanças podem ser separados em abordagens baseadas em *pixel*, em objeto e híbridas, quando as duas técnicas são utilizadas no mesmo processo. A escolha do tipo de método irá depender do propósito da análise, da natureza do fenômeno que se deseja identificar, das características da fonte de dados e da estrutura computacional disponível.

As técnicas de detecção de mudança baseadas em *pixel* foram as primeiras a serem criadas no início do desenvolvimento do sensoriamento remoto, com uma grande variedade de algoritmos criados. Nessa abordagem a análise é feita a partir da relação entre valores dos *pixels* das imagens de diferentes datas. Um aspecto comum entre a maioria delas é a necessidade de se estabelecer limiares para se determinar o que é ou não mudança, que podem ser determinados de forma subjetiva ou a partir de análises estatísticas. As principais técnicas deste tipo de abordagem são descritas por Singh (1989) podendo-se destacar duas delas:

- Diferença de imagens (*Image differencing*)

Considerada uma das mais básicas e amplamente utilizada, esta técnica necessita de imagens de dois momentos diferentes, registradas geometricamente entre si. Com o cruzamento espacial, os valores dos *pixels* de mesma localização são subtraídos, resultando em uma imagem que apresenta a diferença de valores de cada *pixel* entre as duas datas. A partir daí define-se um limiar de valor que represente o tipo mudança investigada para identificar as áreas de mudanças.

– Razão de imagens (*Image ratioing*)

Assim como na técnica anterior, a razão de imagens utiliza pares de imagens de diferentes datas. Porém, neste caso é gerado a razão entre os valores dos *pixels*, dividindo o valor do tempo 1 (t1) pelo do tempo 2 (t2). Se os valores forem iguais ou muito próximos, significando não mudança, o resultado fica próximo a 1

Estas duas técnicas são amplamente utilizadas e podem ser consideradas bases para boa parte de outras técnicas de detecção de mudanças baseada em *pixel*. Segundo Lu et al (2004) elas podem ser incluídas na categoria de técnicas que utilizam a álgebra, na qual são utilizadas operações matemáticas entre os valores de *pixel* das imagens de diferentes datas. As operações podem variar de simples subtração entre valores até a elaboração de índices mais complexos, como índices de vegetação.

Estes autores descrevem a categoria de técnicas baseadas em transformação, que também utiliza operações matemáticas para analisar as mudanças ocorridas, porém, é usado algum tipo de processamento na imagem antes de executar a operação permitindo trabalhar com uma quantidade maior de informação proveniente das variadas bandas das imagens. Esse processamento pode ser por Análise de Principais Componentes (PCA), Gram-Schmidt¹ (GS) ou outros, e tendem a minimizar as redundâncias entre bandas das imagens e enfatizar as diferenças entre os componentes derivados.

Há também modelos baseados em técnicas lineares ou não lineares para transformar os valores de refletância das imagens em parâmetros físicos ou frações destes. Esta abordagem também é utilizada para detecção de mudanças na vegetação, tendo como principal exemplo o modelo espectral de mistura (ROGAN, FRANKLIN e ROBERTS, 2002).

Outros recursos foram desenvolvidos a partir da extração da informação espectral de modo a melhorar a acurácia de classificação de mudanças ou outros fenômenos. Entre eles o mais importante é a textura, que geralmente se refere à medição da variabilidade espacial da vizinhança de *pixels* dentro de uma janela ao longo da imagem. Uma abordagem comum de textura é a estatística, que podem ser de 1° ou 2° ordem, como o desvio padrão e GLCM (*Gray levelco-*

¹ O processo de Gram-Schmidt é um método para ortogonalização de vetores espectrais extraídos de imagens bitemporais (LU et al, 2004).

occurrence matrix), respectivamente. Alguns pesquisadores afirmam que o uso de textura pode ser mais eficiente na detecção de mudanças do que somente as bandas espectrais (WU, YANG e LISHMAN, 2010).

A detecção de mudança baseada em *pixel* é amplamente utilizada por ser uma técnica já consagrada, de fácil aplicação e com uma grande variedade de algoritmos. Porém, para imagens de alta resolução ela não é eficiente, pois os alvos passam a apresentar uma alta variabilidade espectral, são mais suscetíveis à variação da iluminação, aumentando a identificação de falsas mudanças. Nestes casos a abordagem por objetos apresenta uma melhor resposta, pois a delimitação de segmentos minimiza esse efeito. Este procedimento combina segmentação, informações espectrais e espaciais, e a experiência do analista com o objetivo de modelar as entidades geográficas (HAY e CASTILLA, 2008). Quando aplicado para detecção de mudanças é denominado OBCD (*Object-Based Change Detection*) (HALL e HAY, 2003; BLASCHKE, 2005). Esta abordagem apresenta algumas vantagens em relação as análises por *pixel*.

Chen et al. (2012) apontam para três delas: a análise espacial em multiescala, redução de ruídos na classificação e disponibilidade de ferramentas variadas. Uma única escala não é suficiente para apreender todas as características dos objetos de interesse presentes em uma imagem, pois apresentam diferentes características como forma, tamanho e distribuição espacial (HAY, NIEMANN e GOODENOUGH, 1997). As técnicas de detecção com GEOBIA permitem uma alternativa para lidar com essa questão, caracterizando diferentes aspectos da paisagem a partir de uma mesma imagem usando diferentes tamanhos de objetos. Parâmetros de escala, que definem o tamanho médio, mínimo e máximo dos objetos, são usados para otimizar o delineamento de feições individuais e permitem a criação de variados níveis de segmentação relacionados hierarquicamente, possibilitando a individualização de objetos com uma abrangência maior de critérios e uma abordagem em multiescala.

As classificações baseadas em *pixels* tendem a apresentar ruídos em seus resultados, isto é, alguns *pixels* isolados são classificados de forma errada dando uma aparência "salpicada" no produto final, conhecido também como "efeito Monet". Neste caso se faz necessário a aplicação de filtros para uma melhora na classificação. Na abordagem baseada em objeto esse problema é minimizado, pois ao trabalhar com o objeto como unidade mínima de análise, qualquer ruído presente na imagem será incorporado aos objetos de acordo com a especificação de tamanho

mínimo do nível de segmentação. Zhou et al (2008) comparam a abordagem por *pixel* com a de objeto em um estudo de mudanças em áreas urbanas na região metropolitana de Baltimore, encontrando uma acurácia 9% maior na abordagem orientada a objeto. Diferenças de geometria entre as imagens, registro incorreto e diferença de ângulos de visada, também são causadores de ruídos e o GEOBIA apresenta algumas vantagens para lidar com isso. Por exemplo, o registro incorreto acarreta em falsas detecções de mudanças; em uma abordagem baseada em objeto a distinção entre essas falsas mudanças poderia ser feita a partir da criação de condicionantes que envolvam características como forma, tamanho e posição.

Essa capacidade de extrair informações que envolvem forma, tamanho e posição dos objetos faz parte de uma variedade de recursos possíveis com a detecção de mudança baseada em objetos. Assim como na abordagem baseada em *pixel*, a textura também é aplicada aos objetos, porém de forma um pouco mais sofisticada. Ao invés de trabalhar com uma janela de vizinhança fixa, é possível definir o tamanho e a forma da janela a partir das características locais de onde as informações espaciais foram extraídas. Assim, os objetos gerados a partir da segmentação servem como janelas contextuais. Além da textura extraída individualmente a partir de cada objeto, também pode ser gerada uma textura de ordem maior, que considera a distribuição espacial dos objetos adjacentes (CHEN e HAY, 2011). As informações de contexto também podem ser extraídas e condicionantes como contiguidade topológica podem ajudar a uma melhor análise de mudança.

Na abordagem baseada em objeto a detecção de mudança é feita identificando alvos que demonstrem diferença em seus atributos espaciais e/ou espectrais ao longo do tempo. Muitos algoritmos de detecção de mudanças baseados em *pixels* podem ser transferidos para o domínio do objeto. Por exemplo, a ideia de se comparar valores de *pixels* pode ser usada para comparar valores dos objetos. No entanto, os usuários têm que ficar atentos porque os objetos apresentam diferentes tamanhos e formas, o que requer soluções específicas para lidar com as características de relações entre os mesmos.

A principal questão ao utilizar o GEOBIA é como definir as mudanças entre os objetos. A comparação direta entre segmentos do mesmo local em datas diferentes é a opção mais elementar. Eles podem ser comparados usando as informações espectrais e os recursos associados (HALL e HAY, 2003; GONG, SUI, *et al.*, 2008) ou fazendo referência a uma classificação feita *a priori* (BLASCHKE, 2005; DE CHANT e KELLY, 2009; WALTER, 2004). Há ainda a possibilidade de

segmentar o conjunto de imagens temporais de uma só vez, resultando em objetos relacionados a todas as datas (DESCLÉE, BOGAERT e DEUFOURNY, 2006; BONTEMPS, BOGAERT, *et al.*, 2008; STOW, HAMADA, *et al.*, 2008). Neste caso, os aspectos de forma e tamanho não têm muita relevância para a detecção de mudança, pois só há um nível de segmentação.

Chen et al (2012) destacam quatro categorias de algoritmos aplicados na abordagem baseada em objeto para detecção de mudanças: por objetos (*image-object*), por classe dos objetos, por objetos multitemporais e híbridos.

– **Objetos (Image-object)**

Usa o mesmo princípio de comparação da detecção de mudança por *pixel*, porém utilizando os objetos. Por isso, pode-se usar as propriedades geométricas dos objetos (forma, tamanho etc.) ou as propriedades espectrais e seus derivados (ex. textura).

Hall e Hay (2003), desenvolveram uma detecção de mudança baseada em objetos onde primeiro foi segmentado duas cenas pancromática do SPOT e em seguida foi aplicado diretamente um método de diferenciação de imagens para detectar mudanças em objetos no nível de segmentação mais alto. Para evitar a subjetividade na escolha de limiares, um método não paramétrico e não supervisionado proposto por Otsu (1979) foi usado para selecionar limiares de forma automática. Seus resultados revelaram que os ruídos dos sensores relacionados ao efeito de "*striping*" foram efetivamente ignorados e que foi estabelecida uma base para se explorar em múltiplas escalas.

Gong et al. (2008) também usaram a lógica multiescalar. No entanto, ao invés de simplesmente mudarem a resolução da imagem, eles criaram uma árvore de objetos em "*full-scale*", extraindo todos os segmentos usando uma estrutura hierárquica e um modelo de convexidade², onde todos os objetos de diferentes imagens foram segmentados a partir da mesma cena. Objetos espacialmente correspondentes nas duas datas eram então comparados para detectar as mudanças estruturais. Comparada com a segmentação em multiescala tradicional, seus objetos foram extraídos com mais acurácia, o que melhorou a performance da detecção de mudanças.

²O modelo de convexidade considera os valores dos *pixels* como cotas de altitude. A imagem é tratada como uma superfície convexa, onde as áreas suaves representam áreas homogêneas e as acidentadas áreas heterogêneas.

Ao tentar extrair as mudanças existentes entre um par de imagens em níveis de cinza, Miller et al. (2005) apresentam um algoritmo em GEOBIA que detecta novas feições significativas em "blobs"³, que seriam segmentos delineados (objetos). Neste caso, o foco dos autores eram as imagens de vigilância urbana, mas pode ser aplicado em produtos de sensoriamento remoto. Primeiro, os objetos foram extraídos usando análises de conectividade. Segundo, para cada objeto da imagem base buscou-se um objeto correspondente na outra imagem. Para detectar quando dois objetos correspondentes eram realmente diferentes (mudança) foi usado um método de correspondência para apreender a relação entre os limites de *pixels* dos dois objetos. Aplicando essa ideia baseada em objetos, o autor argumenta que o algoritmo proposto funcionou para imagens com ruído e que não foi necessário pré-definir uma janela, pois o processo foi empreendido diretamente nos objetos extraídos.

Chen et al (2012) apontam que, geralmente, os objetos são extraídos diretamente através da segmentação, e as etapas, como a diferenciação de imagens, são similares à detecção de mudanças baseada em *pixels* ou operações de interseções em SIG. No entanto, como os objetos possuem diferentes tamanhos e formas, um procedimento crítico é a busca dos objetos "correspondentes" entre diferentes imagens. Erros na identificação desses objetos levarão a resultados de detecção de mudanças incorretos.

– **Classe do objeto**

As análises de detecções que usam somente o objeto apresentam uma limitação de não informar a natureza da mudança, se foi uma alteração completa do estado do elemento (*de-para*) ou apenas uma modificação nas propriedades do elemento. Dessa forma, a detecção de mudança pelas classes dos objetos permite a comparação de objetos classificados de imagens multitemporais. Visto que cada objeto pertence a uma determinada classe, a etapa de comparação entre objetos não necessita, obrigatoriamente, a consideração de recursos como padrões espectrais e valores de textura.

A utilização de mapas de referências e informações temáticas acrescentam variáveis que ajudam a melhorar a detecção de algumas mudanças, sendo um tipo de aplicação que considera as classes dos objetos. Walter (2004) avaliou a importância da utilização de diferentes dados de

³ Neste caso, o termo "blobs" equivale a segmentos

entrada (ex. espectral, índices de vegetação, textura) em uma classificação orientada a objeto, o que leva a diferentes resultados quando atualiza-se camadas SIG. Ele sugere que a avaliação das características de objetos derivados de dados LIDAR, textura e multitemporais poderá melhorar a performance de classificação e detecção de mudanças. Em outros casos ao invés de se usar um mapa base, cria-se objetos a partir de imagens multitemporais. Laliberte et al. (2004) conduziram uma classificação baseada em objetos em 11 fotos aéreas e 1 imagem Quickbird abrangendo 67 anos. Como os autores estavam interessados apenas nas mudanças de vegetação, os valores totais de mudanças foram calculados sem considerar a distribuição espacial das mudanças e sim as classificações de cada ano de forma separada. Já Owojori et al (2005) efetuaram as classificações separadamente fazendo uma comparação espacial entre elas para localizar as mudanças e gerar uma matriz de conversão de classes.

Como já foi mostrado, Blaschke (2005) propõem um quadro conceitual baseado em SIG onde é definida uma série de regras para distinguir quando a diferença entre objetos é real ou apenas uma inconsistência geométrica. Esse princípio foi aplicado em diversos estudos de detecção por classes de objetos, cada um adaptado a sua condição específica. Para monitorar doenças em árvores, De Chant e Kelly (2009) executaram funções de interseção entre objetos com SIG. Mapas multitemporais, em formato raster, de lacunas florestais derivados de classificações orientada a objetos foram convertidos para polígonos vetoriais para serem cruzados. As mudanças foram identificadas analisando as métricas dos objetos, incluindo área, perímetro, forma e distância euclidiana do vizinho mais próximo.

Complementando a informação geométrica, ainda é válido o uso de medidas espectrais e/ou de textura na comparação entre objetos classificados. Em um estudo conduzido por Anet et al. (2007), uma classificação baseada em objetos foi usada simplesmente para detectar possíveis mudanças em objetos (não urbano para urbano). Uma verificação mais profunda de quando a mudança era real envolvia o cálculo de similaridade entre os objetos usando características espectrais e de textura.

Assim como a detecção de mudança baseada em *pixels*, a performance baseada em objeto é influenciada fortemente pelo procedimento inicial de classificação. Um aprofundamento sobre a acurácia de classificação baseada em *pixels* foi discutido por Foody (2002). Quanto ao paradigma do objeto, a acurácia da classificação também é relacionada a seleção apropriada de técnicas de

segmentação. Com isso, usuários precisam estar cientes de que a propagação de erro da segmentação e classificação irá afetar a performance do resultado.

– **Objetos multitemporais**

As segmentações geradas em diferentes datas frequentemente variam em suas geometrias, mesmo quando representam a mesma feição geográfica. Nesta abordagem, uma única segmentação é aplicada em todas as imagens multitemporais. Especificamente, a sequência temporal de imagens é combinada e segmentada junta, produzindo objetos de mudanças espacialmente correspondidos. Algumas vezes a classificação também é realizada com todas as imagens juntas, ou separadas em intervalos específicos.

Descléet al. (2006) propõem um algoritmo para implementar uma abordagem de detecção de mudança por objetos multitemporais. Os autores segmentaram um conjunto de imagens multitemporais juntas para em seguida calcular as feições espectrais (ex. média, desvio padrão) para cada data em todos os objetos. Finalmente, a discriminação entre mudança e não mudança foi realizada usando uma análise estatística através do teste de qui-quadrado. Com essa abordagem, os autores reportaram alta acurácia na detecção (>90%) e Kappa total (>0.8). Seguindo uma abordagem similar, estudos adicionais desenvolveram algoritmos com base em GEOBIA enfatizando o desenvolvimento de novas formas de caracterizar mudanças no nível do objeto. Bontemps et al. (2008) integraram o cálculo de distância Mahalanobis e métodos de limiares para identificar mudanças em objetos. Stow et al. (2008) compararam o classificador de vizinho mais próximo com a função pertinência Fuzzy para monitorar mudanças em arbustos. O resultado mostrou que o uso do classificador vizinho mais próximo obteve uma performance superior. Além de comparar diferentes classificadores baseados em *pixel* e em objeto, (BONTEMPS, BOGAERT, et al., 2008). Imet et al. (2008) avaliaram a performance da correlação entre objetos de imagens multitemporais, considerando o uso de descritores contextuais na classificação de mudanças na superfície terrestre. Seus resultados revelaram que a incorporação desses recursos aumentou a acurácia da identificação das mudanças (Kappa>0.85). Ao invés de segmentar a combinação de imagens multitemporais, Li et al. (2009) descrevem um procedimento de segmentação para imagens de radar que consiste em (1) segmentar a imagem da primeira data, (2) tratar o resultado como uma camada temática e (3) segmentar a segunda imagem junto com a camada temática. Sua intenção foi fazer com que a segmentação feita previamente "aprisionasse" as segmentações

subsequentes para evitar resultados inconsistentes quando usada uma única segmentação (ex. objetos com variedades de limites).

Para Chen et al (2012), uma segmentação única usando todas as imagens multitemporais facilita criar segmentos consistentes em tamanho, forma e localização ao longo do tempo. No entanto, ainda não é claro o quanto essa forma de segmentação influencia na detecção de mudança considerando que a mesma localização geográfica pode ter diferentes objetos. Similarmente, o efeito de mistura espectral dos objetos (de diferentes condições atmosféricas, ângulo de visada e iluminação) nos resultados de mudança precisam ser explorados.

– **Híbrido**

Este tipo de análise considera o uso das abordagens baseadas em objetos e em *pixels*. Geralmente, a análise em *pixel* é feita em um primeiro momento para extrair as informações preliminares para em seguida aplicar a abordagem baseada em objetos.

Al-Khudhairyet al. (2005) aplicaram a ferramenta de Análise de Principais Componentes (PCA) e diferença de imagens aplicadas aos *pixels* em imagens de alta resolução para identificação de danos estruturais resultantes de conflitos armados. As imagens de mudanças eram então analisadas por uma classificação baseada em objetos. Posteriormente, o autor comparou os resultados com um mapa classificado manualmente, considerado como referência. Foi demonstrado uma melhora de acurácia utilizando a análise baseada em objeto. Yuet al. (2004) aplicaram a segmentação em uma imagem diferenciada de um modelo altimétrico da copa da floresta, gerado a partir de LIDAR. Com dois modelos digitais do terreno de uma mesma área com intervalo de dois anos foi gerada uma camada correspondente a diferenciação dessas imagens. Com ela aplicou-se a classificação baseada em objeto para identificar as mudanças nos indivíduos florestais. Resultados mostraram que árvores cortadas individualmente foram delineadas de forma acurada.

Um algoritmo híbrido foi proposto por Carvalho et al. (2001). Os autores mostraram que a correlação "*waveletinter-scale*" computada por diferença de imagens baseada em *pixel* (ex. razão, PCA) foi eficiente em identificar todas as mudanças de cobertura sobre uma área de estudo. Em seguida foi executada a segmentação por crescimento de regiões apenas nas áreas que mudança, evitando o tempo necessário para segmentar todas as imagens. Os autores concluíram que esta

abordagem não foi afetada por registros incorretos e discrepâncias atmosféricas entre as imagens multitemporais, assim como para as diferenças do estado fenológico das manchas de vegetação. Esse procedimento pode ser automatizado, e desde 2003 vem sendo usado pelo governo de Minas Gerais para atualizar os mapas de vegetação.

Os algoritmos híbridos que combinam projetos baseados em pixel e objeto com sucesso reduzem os ruídos das mudanças, assim como as mudanças menores e espúrias introduzidas pela delimitação inconsistente dos objetos (MCDERMID, LINKE, *et al.*, 2008). Porém, para Chen et al (2012), como a detecção de mudança híbrida envolve muitas etapas, não é muito claro como o resultado final das mudanças é influenciado pelas diferentes combinações das técnicas baseadas em pixel e objeto.

2.5. Exemplos de projetos de análise de mudanças em coberturas vegetais

Atualmente, existem diversos projetos com o objetivo de monitorar a cobertura da terra usando diferentes sensores e metodologias. Aqui serão apresentados três exemplos que utilizam imagens de baixa, média e alta resolução para analisar a dinâmica de coberturas florestais e agrícolas.

Desenvolvido pela Embrapa Informática Agropecuária, o Sistema de Análise Temporal da Vegetação (SATVEG) é uma ferramenta *web* que permite ao usuário visualizar a trajetória histórica de valores de índice de vegetação do sensor MODIS (*Moderate-Resolution Imaging Spectroradiometer*) que expressa as variações de biomassa vegetal na superfície terrestre ao longo do tempo. Há informações para toda a América do Sul e através de uma interface simples é possível selecionar áreas de interesse e determinar períodos específicos para a gerar perfis com os valores dos índices (Figura 2.1).

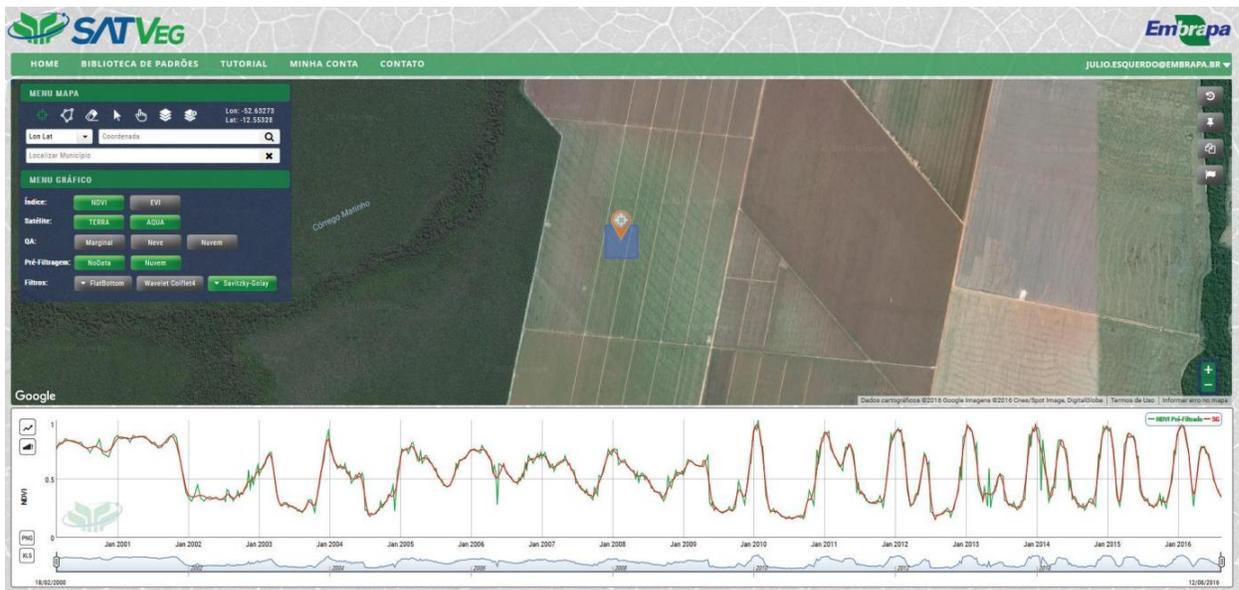


Figura 2.1- Exemplo de perfil de NDVI gerado pelo SATVEG. (Fonte:www.satveg.cnptia.embrapa.br)

Esta ferramenta trabalha com imagens de 250 metros de resolução espacial, sendo indicado a estudos em escalas menores, e os índices utilizados são gerados a cada 16 dias. Não é realizado nenhum processo para detectar mudanças, o usuário pode caracterizá-las a partir das assinaturas dos perfis temporais apresentados. Existe um outro projeto que utiliza as mesmas fontes de informação para detectar mudanças na cobertura florestal na Amazônia. Desenvolvido pelo INPE (Instituto Nacional de Pesquisas espaciais), o DETER (Detecção de desmatamento em tempo real) identifica alterações na cobertura florestal com áreas maiores que 25 ha e informa os órgãos de fiscalização para subsidiar ações. A baixa resolução é compensada pela periodicidade das análises que ocorrem diariamente.

Recentemente, foi lançado um sistema de alerta de distúrbios em cobertura arbórea (HANSEN, KRYLOV, *et al.*, 2016) que abrange vários países em áreas tropicais húmidas. Esse sistema utiliza imagens dos sensores dos satélites Landsat 7 e 8 com resolução de 30 metros, aumentando a escala de análise em relação aos sensores do MODIS. É considerado cobertura arbórea toda vegetação superior a 5 metros de altura e com cobertura de copa de 60% do *pixel*, incluindo florestas naturais e plantadas. Elaborado pelo laboratório GLAD (*Global Land Analysis & Discovery*) da universidade de Maryland, esse sistema funciona a partir de um algoritmo de árvore de decisão que utiliza como variáveis a última observação disponível e métricas geradas a partir das observações anteriores para indicar onde houve supressão florestal. Para um alerta ser

confirmado é necessário ele se repetir pelo menos duas vezes em quatro observações, o sistema é atualizado conforme as imagens são disponibilizadas. Este projeto é apoiado pela *Global Forest Watch* onde pode ser consultado através de uma interface simples e intuitiva no site www.globalforestwatch.org/map. Todo o processamento é executado no *Google Earth Engine*, o que permite uma rápida atualização e divulgação. Vale ressaltar que como esse sistema é voltado para um monitoramento constante de oito em oito dias, só é detectado supressão florestal, pois para analisar a regeneração seria necessário um intervalo de tempo maior.

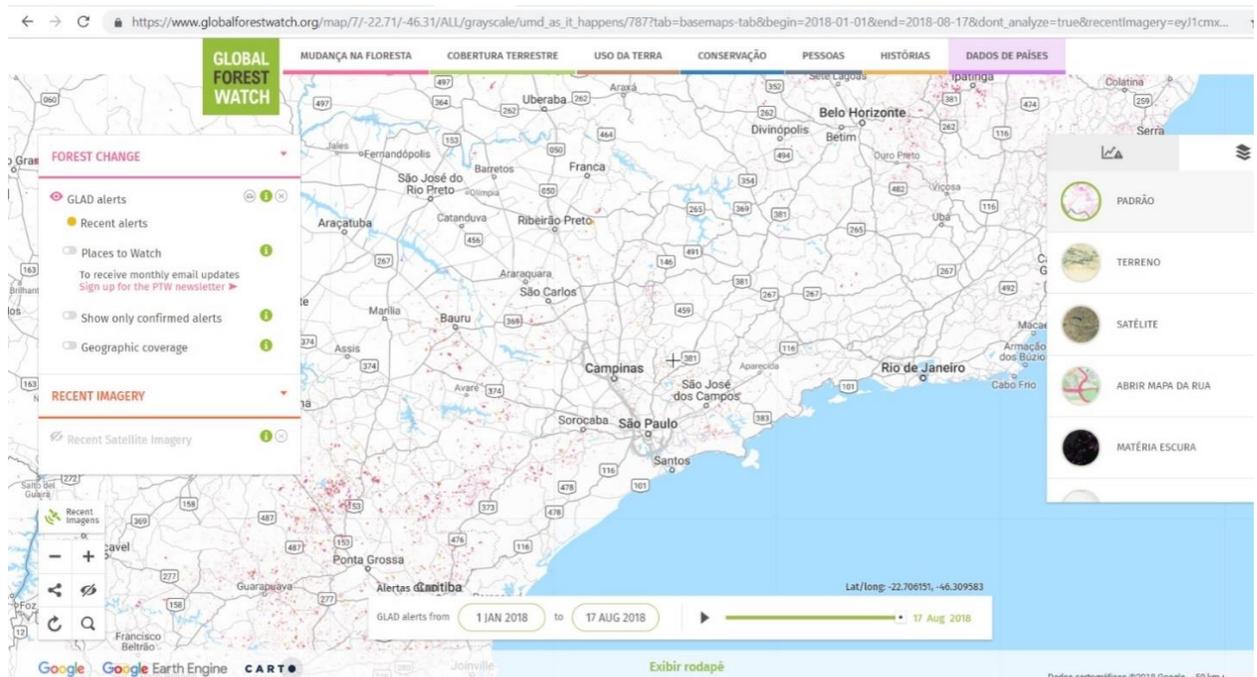


Figura 2.2- Sistema de alerta de supressão florestal GLAD no site *Global Forest Watch*.
(Fonte: www.globalforestwatch.org/map)

Um exemplo de sistema de detecção de mudança utilizando imagens de alta resolução para fins de monitoramento é o projeto Olho no Verde, criado pela Secretaria de ambiente do estado do Rio de Janeiro em 2015. Com o intuito de reforçar ações para o controle da supressão de floresta no estado, a secretaria fez uma parceria com a empresa *Digital Globe* para fornecimento constante de imagens de alta resolução para uma área de aproximadamente 7 000 km² no estado do Rio de Janeiro (Figura 2.3).

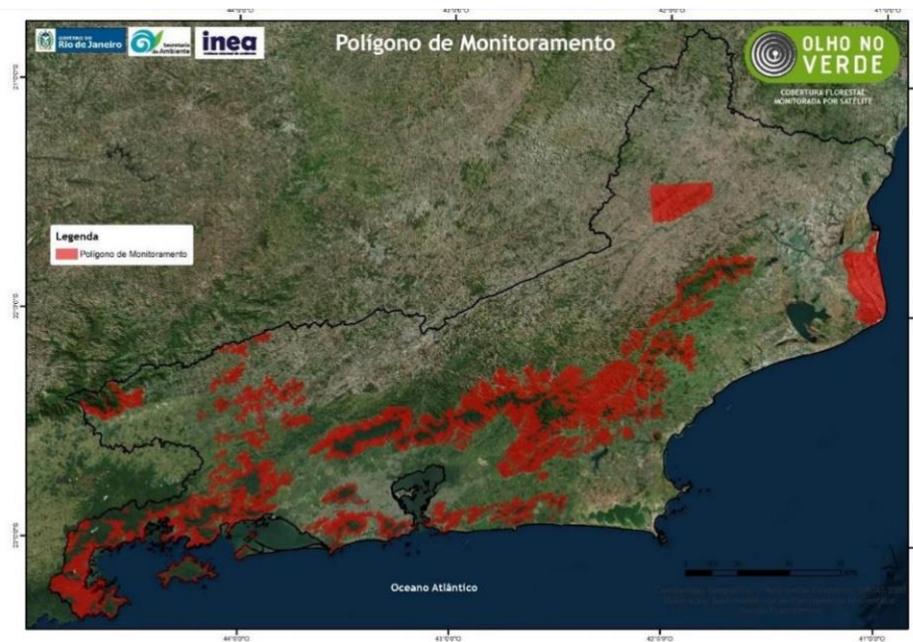


Figura 2.3- Área monitorada pelo projeto Olho no Verde (Fonte: Secretaria de Ambiente do Rio de Janeiro)

A detecção é realizada pela empresa DIGIMAP e o algoritmo utilizado não é divulgado por questões de propriedade. Porém, é de conhecimento que a detecção é feita de maneira bitemporal, comparando a imagem mais recente com uma de referência dependendo das disponibilidades e a área mínima detectável é de 100m². Depois de identificado os polígonos de supressão, eles são validados pela UFRJ e encaminhados para secretaria onde as ações são determinadas.

Os três exemplos demonstram possibilidades de monitoramento de cobertura vegetal utilizando imagens com resoluções variadas e gerando diferentes produtos. Normalmente, as análises com sensores de baixa a média resolução tendem a ser mais automatizadas por já possuírem rotinas de pré-processamentos consolidadas e uma aquisição constante. Já imagens de maior resolução têm uma aquisição intermitente e apresentam maior variação do ângulo de visada, o que dificulta uma sistematização de processos. Porém, com o passar do tempo este tipo de imagem está cada vez mais disponível, seja por satélites ou por Veículos Aéreos Não Tripulados (VANT), o que faz com haja um investimento maior nos sistemas de monitoramento com imagens de alta resolução.

3. Contribuição Metodológica para Detecção de Mudanças em Cobertura Florestal

Neste capítulo será apresentado uma proposta metodológica para detecção de mudanças em cobertura florestal a partir de uma abordagem baseada em objetos em séries históricas de imagens multiespectrais. Resumidamente, este método passa por três etapas: primeiro a normalização das imagens da série histórica para compatibilizá-las e permitir sua comparação, em seguida uma análise multitemporal inicial é realizada para identificar as áreas de cobertura florestal que apresentaram algum tipo de mudança, e por fim, análises bitemporais caracterizam os tipos de mudança em cada período da série. Na Figura 3.1 é apresentado o fluxograma geral com as principais etapas da metodologia.

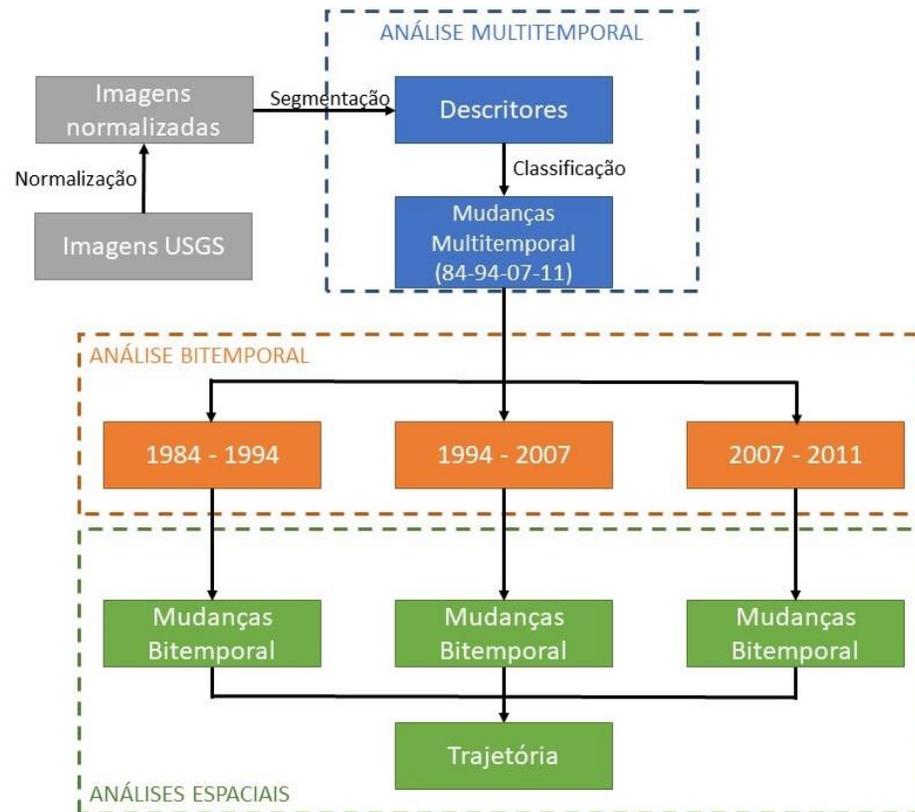


Figura 3.1- Fluxograma da proposta metodológica

No decorrer do capítulo será mostrada a área de estudo escolhida, as imagens escolhidas, o pré-processamento utilizado e todo o processo de modelagem e classificação desenvolvido para essa aplicação.

3.1. Áreas de estudo

No presente estudo foi escolhida uma área piloto para a elaboração metodológica da análise de mudanças em coberturas florestais. Optou-se pela bacia hidrográfica do Rio São João, localizada na porção leste do Estado do Rio de Janeiro abrangendo todo o município de Silva Jardim e parcialmente os de Casemiro de Abreu, Araruama, Rio Bonito, Cabo Frio, Cachoeiras de Macacu, Rio das Ostras e São Pedro da Aldeia (Figura 3.2).

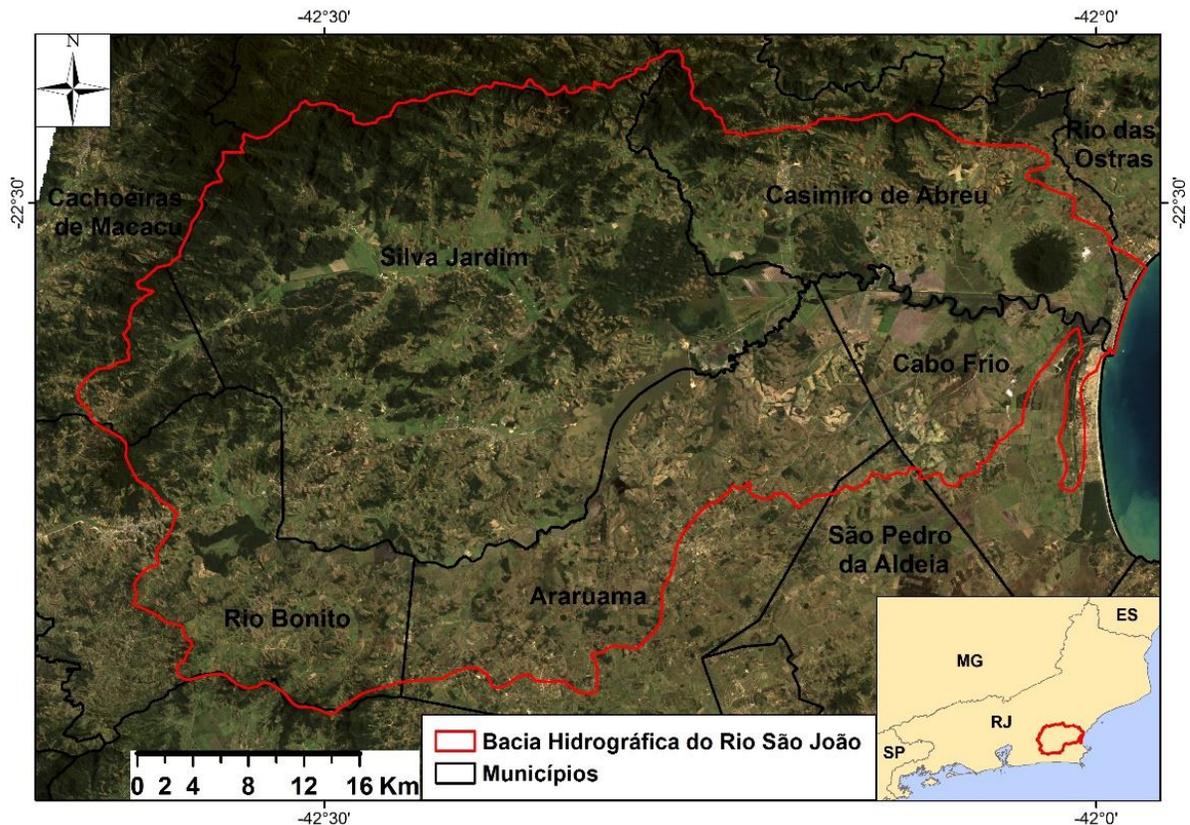


Figura 3.2- Área de estudo piloto, Bacia Hidrográfica do Rio São João

Com uma área total de aproximadamente 2.160 Km², esta bacia é uma das principais fontes de água da região e das baixadas litorâneas através da represa de Juturnaíba localizada na região central da bacia e abastecida pelos rios São João, Bacaxá e Capivari. Ela apresenta uma diversidade de ambientes, com montanhas escarpadas da serra do mar a norte e noroeste, maciços costeiros e interiores situados próximos aos limites de Rio Bonito e planícies aluviais suavemente colinosas localizadas a leste da bacia (Figura 3.3). A cobertura florestal ombrófila concentra-se, principalmente, na porção montanhosa, mas existe a presença de alguns remanescentes na parte baixa da bacia, tendo como destaque a Reserva Biológica Poço das Antas.

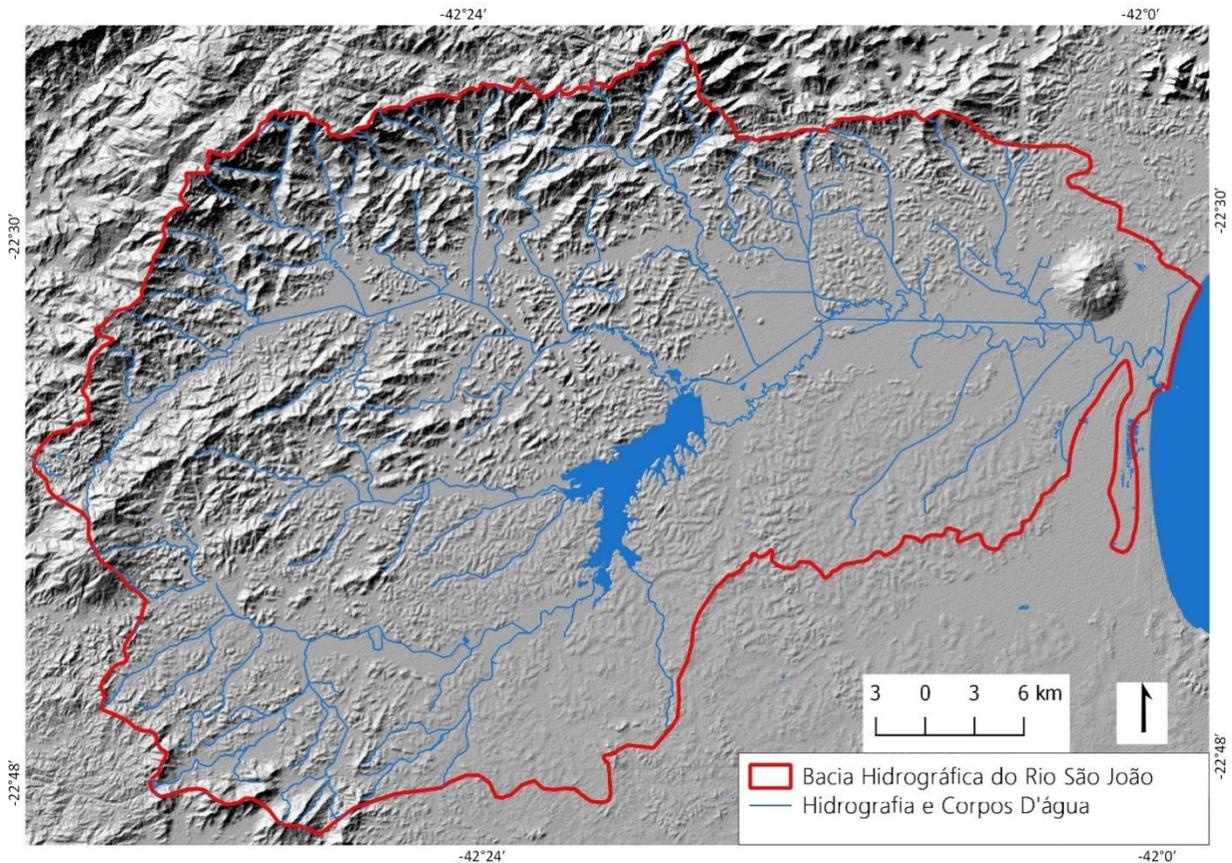


Figura 3.3- Relevo, hidrografia e corpos d'água da BHSJ

A escolha dessa área piloto se deve, principalmente, ao fato da grande disponibilidade de dados sobre a bacia. Ela já vem sendo estudada há alguns anos através de pesquisas acadêmicas por professores e alunos de diferentes instituições, sob diferentes temáticas (REIS, 2008; SEABRA, 2012; ALBUQUERQUE, 2010; GONÇALVES, 2012). Como o presente estudo tem por objetivo geral contribuir para o desenvolvimento metodológico, a variedade de informações disponíveis através desses trabalhos servirá como referência para essa pesquisa.

3.2. Materiais e processamento digital de imagens

A fonte de dados das imagens será a série histórica do sensor orbital *ThematicMapper* (TM). A bordo no satélite Landsat 5, este sensor possui um catálogo de 27 anos de imagens que vai de 1984 até 2011 e estão disponíveis gratuitamente. São imagens indicadas para mapeamentos temáticos em escalas regionais a partir de 1:100.000 com resolução espacial de 30 metros na maioria das bandas (a banda do termal tem 90 metros) e resolução temporal de 16 dias. Possui 7 bandas que variam do azul ao infravermelho termal (Tabela 1) e resolução radiométrica de 8 bits.

A USGS também fornece outras bandas que indicam a qualidade dos *pixels* relacionada à cobertura de nuvem, inclinação solar e falhas no instrumento, conhecidas como *Quality assessment bands* que são úteis para avaliação das escolhas das imagens.

Tabela 1- Bandas espectrais dos sensores TM e seus comprimentos(micrômetro)



Nome	Landsat 5 TM (μm)	
Azul (B)	Banda 1	0.45-0.52
Verde (G)	Banda 2	0.52-0.60
Vermelho (R)	Banda 3	0.63-0.69
NIR (N)	Banda 4	0.76-0.90
SWIR 1 (S1)	Banda 5	1.55-1.75
Termal	Banda 6	10.40-12.50
SWIR 2 (S2)	Banda 7	2.08-2.35

A área de estudo está inserida totalmente na cena 216/76, o que facilita o processamento. Foram selecionadas quatro datas nos anos de 1984, 1994, 2007 e 2011 para analisar as mudanças nas coberturas florestais no intervalo de 27 anos (Figura 3.4). Com isso, há um intervalo de 10, 13 e 4 anos⁴, respectivamente, entre as datas selecionadas. Foi escolhido o período seco entre final de setembro e início de outubro com uma diferença máxima de 21 dias entre as datas, minimizando, assim, as diferenças decorrentes da inclinação solar e aspectos sazonais.

⁴Inicialmente, tentou-se incluir as imagens do sensor OLI do Landsat 8 para manter um intervalo de aproximadamente dez anos, porém, devido a incompatibilidade radiométrica optou-se por usar somente o sensor TM.

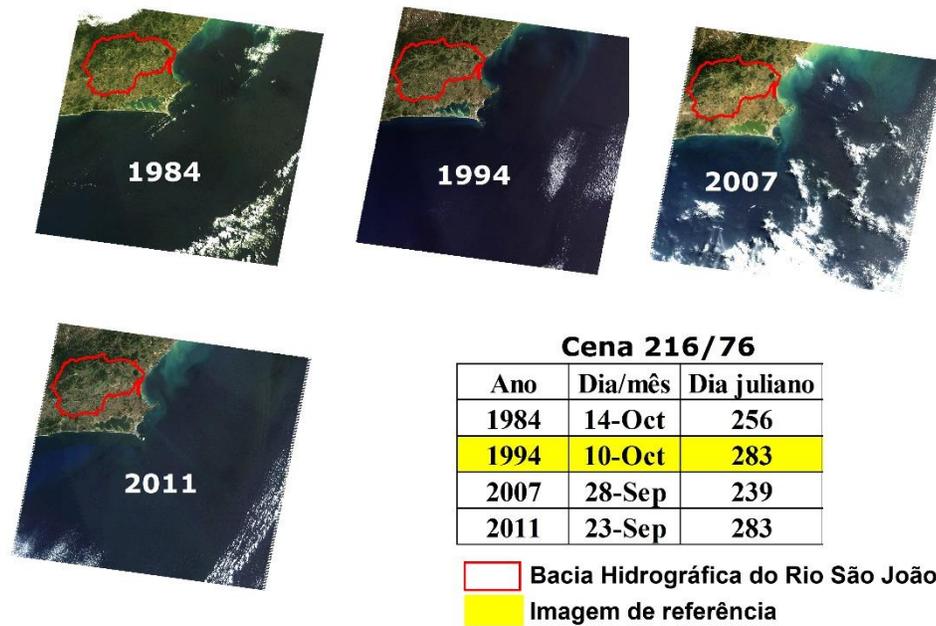


Figura 3.4- Cenas 216/76 do sensor TM

As imagens foram adquiridas através do *site* do USGS (*United States Geological Survey*) em valores de reflectância de superfície, com o nível de processamento L1TP, onde já são corrigidas radiometricamente e geometricamente pela instituição, e em sistemas de coordenadas UTM fuso 24S no Sistema Geodésico WGS84 (que no mapeamento será diretamente associado ao SIRGAS2000). Vale ressaltar que os valores de reflectância são apresentados em números inteiros, resultado da multiplicação do valor original (que varia de 0 a 1 em números reais) por 10 000. A correção geométrica é feita a partir dos metadados da cena, pontos de controle no terreno (GCP) e modelo digital de elevação (MDE) para corrigir erros de paralaxe derivados da topografia local (USGS). Foi realizada uma análise do ajuste geométrico entre as imagens da série histórica selecionada e encontrou-se um deslocamento inferior a 1 *pixel*, o que garante precisão para estudos de detecção de mudança em escalas regionais. A correção atmosférica é executada através do *software Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS) desenvolvido pela NASA em parceria com a Universidade de Maryland. O programa aplica a rotina de correção atmosférica do MODIS (*Moderate Resolution Imaging Spectroradiometer*) nas imagens dos sensores utilizados nos satélites Landsat 4, 5 e 7. A partir de informações de vapor d'água, ozônio, aerossol, modelo digital de elevação e metadados das imagens, o uso do modelo de transferência

radiativa 6S gera imagens de reflectância no topo da atmosfera (TOA), reflectância de superfície, brilho da temperatura no topo da atmosfera e máscaras para nuvens, sombra de nuvem, nuvens adjacentes, terra e água.

Para estudos de detecção de mudança apoiados em séries temporais de imagens se faz necessário outros processamentos digitais, além dos realizados pelo fornecedor, para fins de comparação. Apesar da série temporal utilizada ser do mesmo sensor e captadas na mesma época do ano, diversos fatores, tais como condições atmosféricas, fenológicas, climáticas, topográficas, desgaste do sensor, e etc., podem resultar respostas espectrais diferentes de alvos que não alteraram suas propriedades físicas ao longo do tempo. Para isso, existe o processo de normalização radiométrica, que consiste em técnicas de calibração relativa através da regressão linear entre imagens multiespectrais multidas em relação a uma imagem de referência (PONZONI e SHIMABUKURU, 2009). A imagem de 1994 foi selecionada para ser a referência por apresentar melhores condições atmosféricas e poucas nuvens. Nesse estudo optou-se por usar o modelo de regressão por mínimos quadrados a partir de pontos pseudoinvariantes (PIF) (HALL, STREBEL, *et al.*, 1991). Os PIF são valores extraídos de *pixels*, selecionados manualmente ou automaticamente, que não apresentam mudança na cobertura da terra entre as imagens e que, em teoria, deveriam ter a mesma resposta espectral. O ideal é que se encontre *pixels* de tons claros e escuros de modo a cobrir assinaturas espectrais variadas. Foram escolhidos 90 PIF considerando toda a série histórica, de forma a ser possível usar o mesmo conjunto de pontos para as normalizações das imagens de 1984, 2007 e 2011. Dos 90 PIF, 50 são referentes à cobertura florestal, 15 gramíneas, 11 solo exposto, 5 água, 4 sombra, 3 cordões arenosos e 2 área construída.

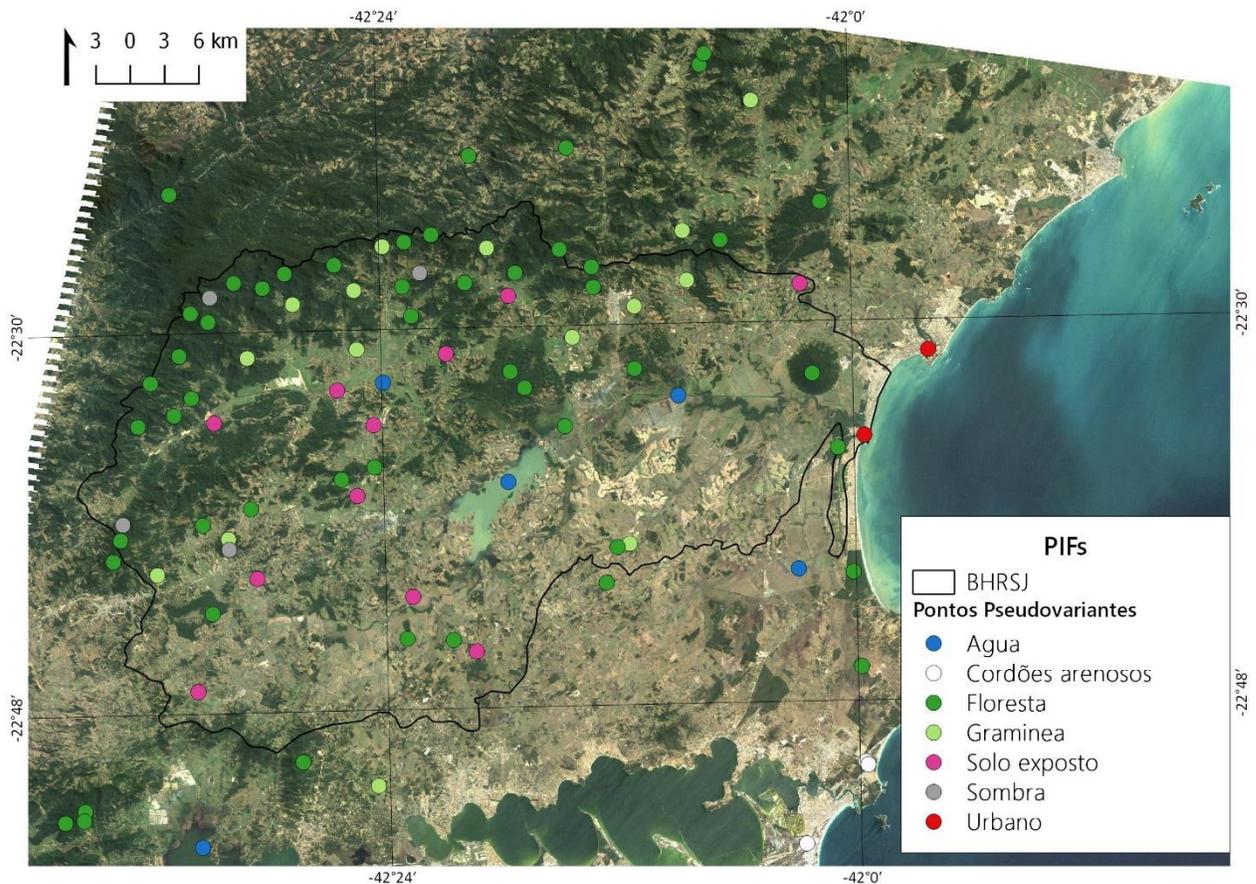


Figura 3.5- Pontos pseudovariantes usados no processo de normalização

Optou-se por dar um peso maior as áreas com cobertura florestal pois o foco desse estudo são as mudanças nesse tipo de classe. Os processos de normalização foram realizados em ambiente R, software de estatística computacional e gráficos que possui uma linguagem própria e a possibilidade de instalar diversos pacotes para trabalhar com diferentes tipos de dados, como imagens *raster*. Através de um *script* desenvolvido por Fernandes et al (2017), foram executadas as funções que resultam em novas imagens normalizadas, geram um gráfico de dispersão com as equações e coeficientes de determinação para cada banda e uma tabela com os valores dos PIF das imagens de referência, antes e depois da normalização, além do erro médio quadrático (RMSE). Na Figura 3.6 é apresentado o fluxo de etapas do processo da normalização.

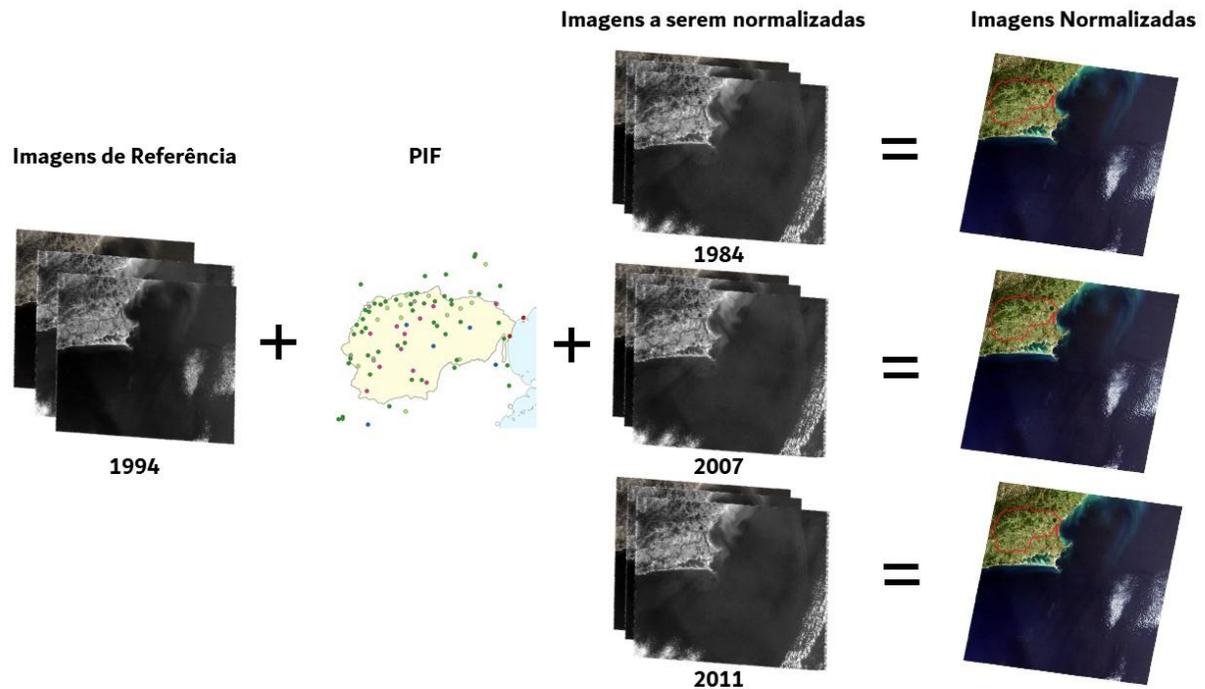


Figura 3.6- Fluxograma do processo de normalização

Com o intuito de criar uma metodologia simples e um processo que não exija grande capacidade de processamento, optou-se por utilizar somente duas variáveis no processo de classificação: a imagem referente ao NDVI (*Normalized Difference Vegetation Index*) (ROUSE, HAAS, *et al.*, 1974), que é gerada a partir de uma relação aritmética (Fórmula1) entre as bandas do Vermelho (R) e Infravermelho próximo (N), e a banda do Infravermelho de ondas curtas (SWIR2). Dessa forma, procurou-se escolher bandas que abrangessem a maior parte da faixa espectral captada pelo sensor evitando redundâncias entre as bandas disponíveis. As bandas escolhidas têm características que favorecem aplicações voltadas para a vegetação. O NDVI é um índice já consagrado e muito útil para diferenciar a cobertura vegetal, enquanto a banda do SWIR2 também é indicada para estudos de vegetação, por sofrer menos influência da atmosfera e ser sensível à presença de água. Esta banda apresenta uma assinatura espectral da vegetação com valores entre o vermelho e o infravermelho próximo, diversificando mais os tipos de resposta espectral das bandas utilizadas.

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

Fórmula1- NDVI (*Normalized Difference Vegetation Index*)

Com as imagens normalizadas a etapa seguinte consistiu em criar um projeto no software eCognition 9.0 para modelagem da detecção de mudanças. As oito imagens, duas para cada data, foram inseridas no projeto para iniciar o processo de segmentação em uma abordagem multitemporal, isto é, utilizando as informações da série histórica conjuntamente para gerar um nível de segmentação único para todos os intervalos. Optou-se por utilizar a abordagem *bottom-up*, onde é definido um primeiro nível de segmentação de maior detalhe que serve de base para níveis superiores a partir da generalização dos segmentos. Esses níveis ficam organizados de forma hierárquica tendo como referência os limites dos segmentos do primeiro nível, e a cada nível criado acima os segmentos são agregados de acordo com os parâmetros escolhidos. Esses parâmetros estão relacionados ao algoritmo utilizado, ao peso dado a cada banda, ao tamanho mínimo do segmento e critérios de forma e cor do *pixel*.

O primeiro nível de segmentação foi criado utilizando apenas as bandas do SWIR2 com peso igual para elas. Para isso, usou-se o algoritmo *Multiresolution Segmentation* (Figura 3.7) que executa a segmentação em função de critérios de homogeneidade, que são estabelecidos a partir de aspectos espectrais e de forma.

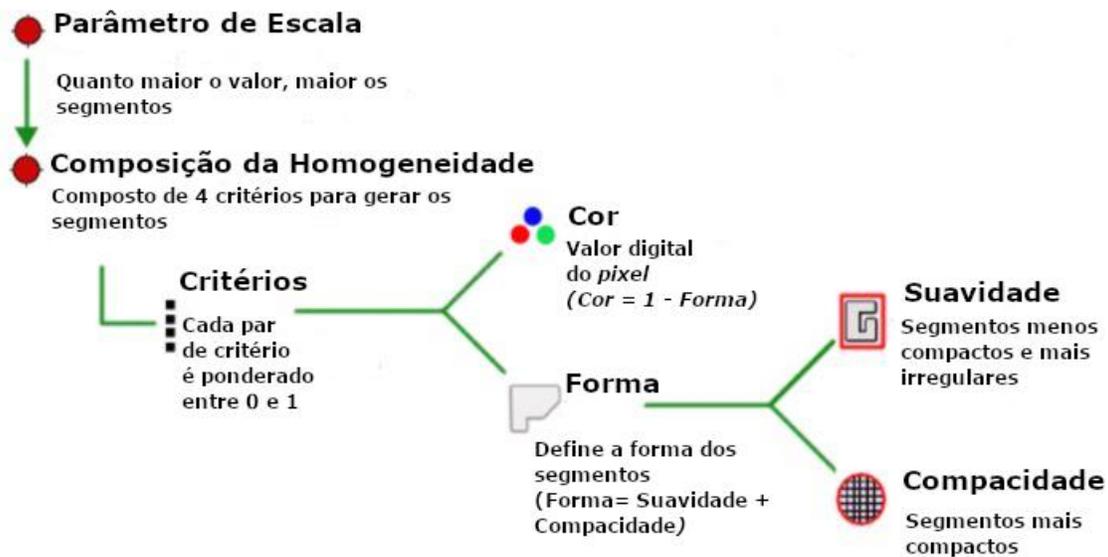


Figura 3.7- Parâmetros para o algoritmo Multiresolutionsegmentation. (Fonte: Adaptado e traduzido de Trimble, 2014)

Para isso, é necessário definir três parâmetros: escala, forma e compacidade. O parâmetro de escala é o valor que define o tamanho dos segmentos, quanto maior este valor maiores os

segmentos. Ele está relacionado com a resolução espacial da imagem a ser segmentada, pois dependendo do tamanho do *pixel*, o mesmo valor de escala pode resultar segmentos de diferentes tamanhos. O parâmetro de forma varia de 0 a 1, e determina o peso entre a cor (valor do *pixel*) e a forma dos segmentos na execução do algoritmo. É possível ponderar de forma equacionada ou dar maior peso a um deles. Quanto mais próximo o parâmetro de 0, maior será a influência da cor, e quanto mais perto de 1, maior a influência da forma. Na prática, este parâmetro só vai até 0,9, pois não considerar o aspecto espectral na segmentação iria resultar em segmentos totalmente desconectados das imagens. O parâmetro de compacidade tem maior influência quando é dado maior peso ao parâmetro da forma. Ele também varia de 0 a 1 e pondera entre suavidade (*smoothness*) e compacidade (*compactness*), quanto mais próximo de 0 os segmentos serão mais compactos e quanto mais perto de 1 eles serão mais irregulares e menos compactos.

Considerando a resolução das imagens TM usadas nesse estudo e através de alguns testes com diferentes configurações, foi escolhido o valor 30 como parâmetro de escala, resultando em segmentos pequenos (variando de 5 a 100 *pixels* por segmento). O parâmetro de cor obteve praticamente peso total com o valor de 0,01, enquanto o valor do parâmetro de compacidade foi de 0,1, para gerar segmentos menos compactos. Dessa maneira o nível de segmentação ficou bem detalhado, com o intuito de separar as potenciais mudanças na cobertura através das diferenças espectrais das imagens multitemporais.

Considerado que as áreas de mudança de cobertura representam apenas uma parte da área de estudo, não há a necessidade de toda a segmentação possuir esse grau de detalhe pois as áreas homogêneas sem alteração na cobertura poderiam ser delimitadas por segmentos maiores. Para isso, foi gerado um novo nível de segmentação acima, agrupando os segmentos de áreas homogêneas ao longo do tempo através da função de segmentação *Spectral Difference*. Este algoritmo tem a função de generalização, refinando segmentações já existentes através de um limiar de diferença entre os valores médios dos segmentos vizinhos (Figura 3.8).

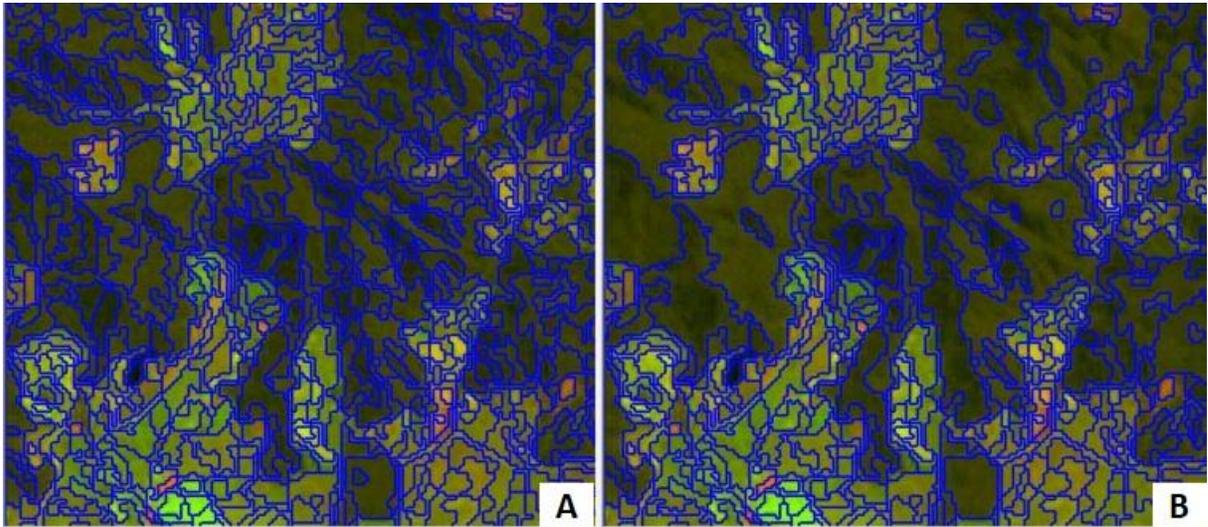


Figura 3.8- Comparação das segmentações utilizando os algoritmos Multiresolutionsegmentation (A) e o spectraldifference (B)

Se a diferença estiver abaixo do valor do limiar os segmentos são unidos (TRIMBLE, 2014). Com isso, em um mesmo nível de segmentação se encontram segmentos maiores em áreas mais homogêneas e segmentos menores em áreas heterogêneas. Para esta função foi utilizado o limiar de 0,02 para as quatro bandas de NDVI da série temporal com pesos iguais entre elas. Assim, priorizou-se a simplificação dos segmentos em áreas de cobertura vegetal. Este nível de segmentação foi usado como uma base única para todas as classificações efetuadas: multitemporal e bitemporal.

3.3. Modelagem e classificação

Com os segmentos definidos, foi desenvolvido um modelo multitemporal considerando todas as datas disponíveis com o objetivo de, primeiro, separar todas as áreas que em algum momento foi associada à cobertura florestal, e em seguida subdividi-las em áreas que apresentaram ou não mudança na cobertura. Foi criada uma árvore de decisão onde as classes se estruturam hierarquicamente a partir de limiares booleanos (Figura 3.9Figura 3.1)

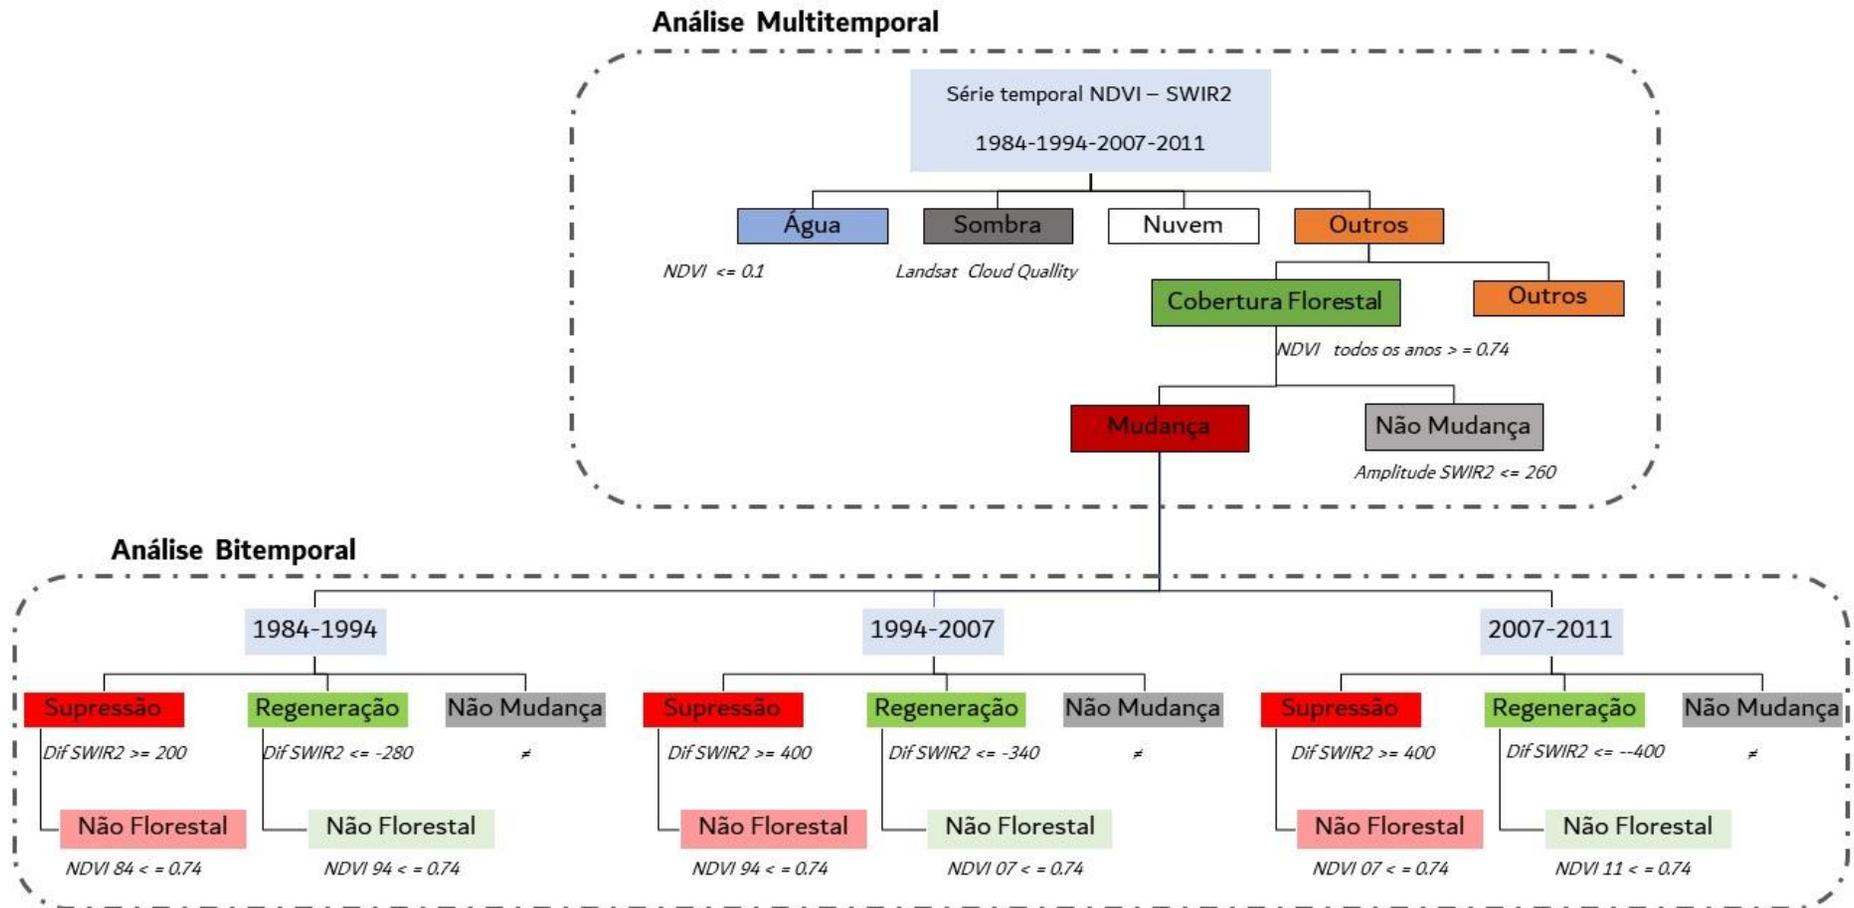


Figura 3.9- Árvore de decisão do modelo de classificação

Inicialmente delimitaram-se máscaras das áreas de nuvem e sombra a partir das informações das bandas *cloud quality assessment*. A maioria das áreas de nuvem estavam fora da área de estudo. Em seguida foram classificadas todas as áreas que em algum momento da série histórica estavam associadas à água usando as bandas do NDVI com limiares booleanos abaixo de 0,1 para cada ano juntamente com o operador condicionante “ou”. O mesmo foi feito para classificar as áreas de cobertura florestal, utilizando-se as bandas do NDVI com limiar maior ou igual a 0,74 e condicionante “ou” entre cada banda (Figura 3.10).

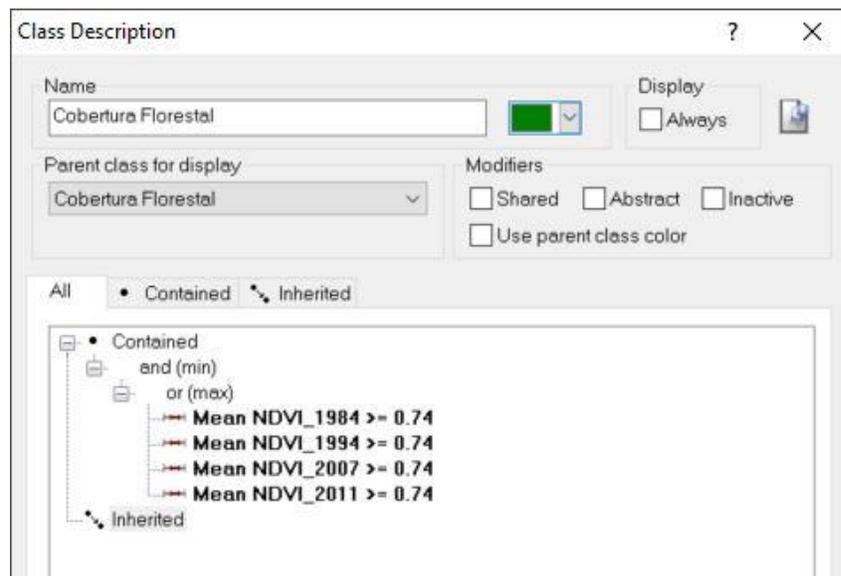


Figura 3.10- Exemplo do modelo multitemporal para cobertura florestal

Para diferenciar as áreas de cobertura florestal que apresentaram ou não mudança foi criado um descritor a partir das informações da banda do SWIR2 e modelagem do conhecimento. Considerando que em um determinado segmento houve mudança na cobertura florestal, ela apresentará diferentes respostas espectrais em cada data, quando houver floresta o valor do SWIR2 será baixo e quando não houver, será mais alto. Já quando o segmento está localizado em uma área de floresta estável, os valores de cada ano tenderão a ser mais próximos. Se compararmos os valores de um segmento na série histórica, haverá uma maior variação nas áreas que tiveram mudança, o que faz com que seja mais coerente criar um modelo para classificar as áreas onde não aconteceram mudanças. Para isso, foram definidas duas variáveis para gerar um descritor que fosse possível

diferenciar essas áreas: Máximo SWIR2 e Mínimo SWIR2. O máximo SWIR2 é calculado para todos os segmentos a partir da identificação do maior valor de SWIR2 em toda a série histórica, ou seja, cada segmento armazenará o maior valor desta banda entre as quatro datas analisadas. O Mínimo SWIR2 segue esta mesma lógica, porém, contabilizando os valores mais baixos da série histórica. Com isso, calculou-se o descritor Amplitude do SWIR2 subtraindo a variável Mínimo SWIR2 da variável Máximo SWIR2 (Fórmula 2).

$$\textit{Amplitude SWIR2} = \textit{Máximo SWIR2} - \textit{Mínimo SWIR2}$$

Fórmula 2- Amplitude SWIR2

Com esse descritor definido, entende-se que os segmentos com os valores mais próximos de zero tendem a ser áreas sem mudança na cobertura florestal, pois os valores máximos e mínimos do SWIR2 estariam muito próximos, indicando uma área estável. A partir da definição de um limiar para esse descritor é possível separar as áreas de mudança das áreas estáveis. O limiar de 260 foi escolhido a partir de uma análise exploratória dos dados, e todos os segmentos abaixo desse valor foram classificados como não mudança da cobertura florestal. Por exclusão, os que tiveram valor acima deste limiar foram classificados como mudança. Vale lembrar que os valores das bandas do SWIR com correção atmosférica são multiplicados por 10.000, logo o valor do limiar corresponde a 0,026 na escala de 0 a 1 da reflectância.

Após a classificação das áreas de mudanças, o passo seguinte foi caracterizar os tipos de mudança, supressão ou regeneração, e quando elas ocorreram. Para isso, usou-se uma abordagem bitemporal, classificando as mudanças de cada intervalo consecutivo de datas, resultando em três períodos: 1984-1994, 1994-2007, 2007-2011.

O nível de segmentação e classificação das áreas de mudança em cobertura florestal foi replicado para servir de base para a classificação das mudanças em cada intervalo. Utilizando a função *copy image object level* a segmentação e classificação foram copiadas e renomeada para um nível acima. Esse procedimento foi repetido para cada intervalo, gerando três níveis de segmentação iguais para serem classificados separadamente. Dessa forma, se mantém a mesma estrutura de segmentos para todos os períodos resultando em um único produto final com as informações de todos os intervalos

A modelagem para cada intervalo definiu as classes: Supressão, Regeneração e Não Mudança. A classe Não Mudança se faz necessária novamente pois é possível ter áreas inalteradas em apenas um período, já que a primeira classe Mudança considerou todos os objetos que apresentaram pelo menos uma mudança em todo o período de 27 anos analisados. Para fazer a distinção entre as classes usou-se o descritor da diferença das bandas do SWIR2 dos anos de cada intervalo, diminuindo o valor do ano mais antigo (T1) do mais recente (T2) (Fórmula 3).

$$\text{Diferença de SWIR2} = \text{SWIR2 do T2} - \text{SWIR2 do T1}$$

Fórmula 3- Diferença de SWIR2

A grosso modo, os valores negativos tendem a indicar áreas de regeneração, enquanto os positivos de supressão. Isto porque a vegetação absorve mais as ondas eletromagnéticas dessa faixa do espectro, resultando em valores mais baixos. Então, em uma área de supressão o valor do ano mais recente sempre será mais alto do que o valor do ano antigo, e vice-versa. Os limiares para separar as classes variaram ligeiramente em cada intervalo. Os limiares usados nos três intervalos podem ser observados na Tabela 2.

Tabela 2- Limiares usados no descritor Diferença de SWIR2

Período	Supressão	Regeneração
1984-1994	≥ 200	≤ -280
1994-2007	≥ 400	≤ -340
2007-2011	≥ 400	≤ -400

O descritor de diferença de SWIR2 não é suficiente para classificar as áreas de supressão e regeneração florestal, pois acaba englobando mudanças que envolvem coberturas não florestais como, por exemplo, áreas agrícolas onde ocorreram colheitas durante o intervalo e que foram classificadas como supressão, ou áreas de queimadas que tiveram o crescimento de vegetação herbácea, e que foram classificadas como regeneração. Para isso, subdividiu-se as classes de Supressão e Regeneração para separar essas mudanças não florestais utilizando o NDVI como descritor. Os segmentos que possuíam valor de NDVI abaixo do limiar usado foram classificados como mudança não florestal. Foi aplicado o mesmo limiar usado na análise multitemporal, mas como a intenção é classificar as mudanças em cobertura não florestal, o modelo incluiu os valores abaixo do limiar. Por exemplo, no período de 1984-1994 a classe de Supressão Não florestal usou-

se o NDVI de 1984 com um limiar menor ou igual a 0,74, para garantir que o segmento não fosse cobertura florestal em 1984 (Figura 3.11). Já para a Regeneração Não Florestal o limiar foi aplicado no NDVI de 1994, excluindo os segmentos que não eram cobertura florestal em 1994. Todos os segmentos que não se enquadraram nos modelos das classes de Regeneração, Supressão e Não Florestais foram classificados como Não Mudança através da condicionante *not*.

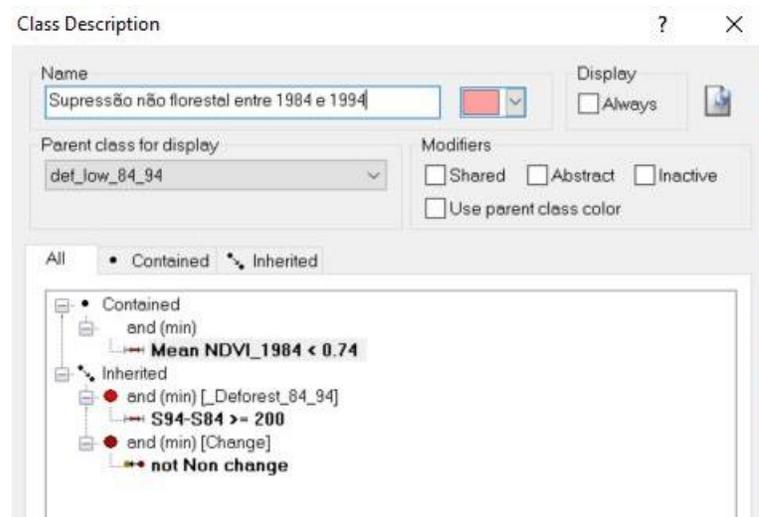


Figura 3.11- Exemplo do modelo para classificação de supressão não florestal

Com a classificação finalizada, a etapa seguinte foi a exportação para o formato *shapefile* para generalização dos segmentos e análise da informação. Como os três níveis de classificação (84-94; 94-07 e 07-11) possuem o mesmo total de objetos, foram exportados em um arquivo único, onde as classes de cada período são separadas em colunas na tabela de atributos. O processo de generalização ocorreu em duas etapas: a fusão de segmentos contíguos da mesma classe e a eliminação de objetos menores que a 1 hectare. Utilizando a função Dissolver do programa Qgis uniu-se os segmentos de mesma classe considerando as configurações dos três intervalos. Com o arquivo generalizado, foram apagados todos os objetos com menos de 1 hectare que estavam isolados, os que possuíam vizinhança foram fundidos com a classe de maior superfície de contato. Com esse arquivo foi possível estabelecer trajetórias de mudanças a partir das combinações de classes no período e também criar uma tipologia temporal da cobertura florestal identificando as idades dos fragmentos florestais e das áreas que foram suprimidas. Assim se atingiu o produto final da classificação que será analisado no próximo capítulo.

4. Análise dos resultados

Nesse capítulo serão analisados os resultados encontrados referentes ao processo de normalização das imagens, a exatidão dos produtos gerados e as classificações resultantes da metodologia proposta.

4.1. Quanto à normalização

Para avaliar o resultado das imagens normalizadas foram usadas duas informações: o erro médio quadrático estimado no processo de normalização e a análise amostral dos valores de *pixels*. Esses erros são produtos, juntamente com gráficos e tabelas, do *script* em R (R CORE TEAM, 2018) usado para rodar o processo e podem ser conferidos nos anexos. A seguir, a Tabela 3 apresenta o resumo dos valores encontrados para as bandas de cada ano.

Tabela 3-Resumo do erro médio quadrático do processo de normalização

Ano	Vermelho	NIR	SWIR 2
1984	0.96	0.87	0.96
2007	0.96	0.92	0.95
2011	0.98	0.91	0.96

Observa-se que em quase todas as bandas o RMS está acima de 0.9, com exceção da Banda NIR de 1994 que apresentou o valor de 0.87. Considerando que esse indicador varia de 0 a 1, estatisticamente os resultados são muito bons. Vale ressaltar que não há valor para o ano de 1994 porque este ano foi usado como imagem de referência em função das melhores condições atmosféricas.

Para analisar o resultado da normalização, comparando-se os valores dos *pixels* de antes e depois do processamento, foram coletadas amostras em três tipos de coberturas: Floresta, Gramínea e Solo exposto. Como este trabalho tem o objetivo de mapear as mudanças na cobertura florestal, priorizou-se analisar o resultado sob a ótica dos tipos de coberturas que estão relacionados a esse tema, como floresta e gramínea. O Solo exposto foi escolhido por apresentar uma resposta espectral mais clara e assim poder analisar a normalização considerando uma ampla faixa de assinaturas espectrais, variando de alvos claros a escuros. Optou-se por não analisar amostras de agricultura, apesar de estar relacionada ao tema, pois ela possui uma heterogeneidade na sua assinatura

espectral devido aos diferentes tipos de cultivo e estágios, o que dificultaria avaliar a qualidade da normalização.

Foram escolhidos 5 pontos amostrais de cada classe em regiões onde não foi observada variação durante o período, extraindo-se os valores de cada *pixel* das bandas usadas nos quatro anos, antes e depois do processo de normalização. Foram calculadas as médias das 5 amostras e plotadas em gráficos representando os valores antes e depois da normalização. A seguir, pode-se observar o Gráfico 4.1 e o Gráfico 4.2 com os valores das amostras de floresta nas imagens em valor de reflectância e nas imagens normalizadas, respectivamente.

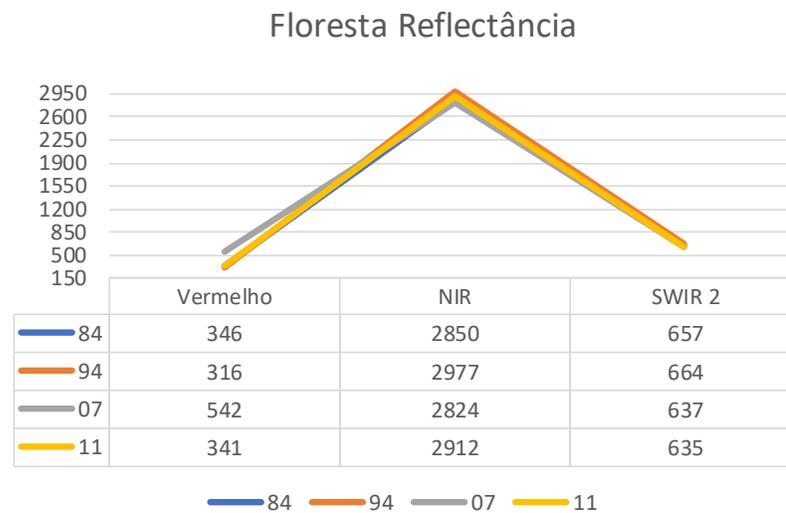


Gráfico 4.1- Amostras de floresta nas imagens em valor de reflectância

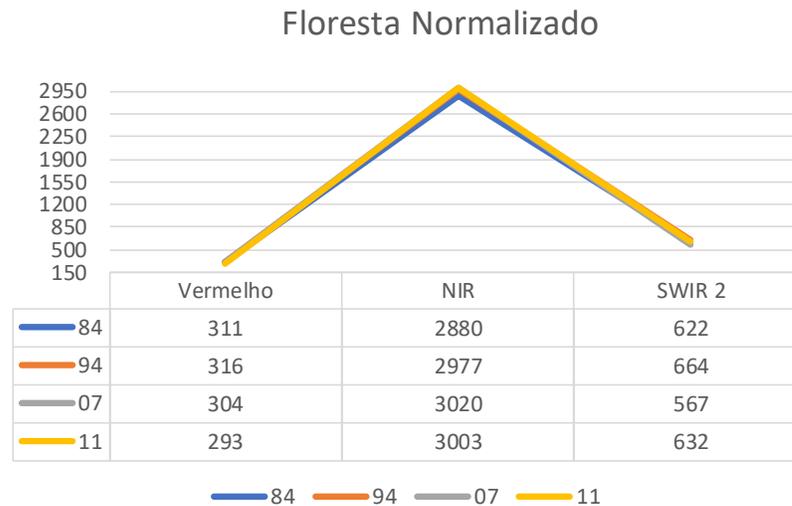


Gráfico 4.2- Amostras de floresta nas imagens normalizadas

Nas amostras de floresta pode-se perceber um melhor resultado na banda do vermelho, tendo como referência as imagens de 1994, onde em todos os anos os valores se aproximaram à imagem de referência. No NIR os valores também se aproximaram, sendo que nos anos de 2007 e 2011 o valor anterior ao processamento estava abaixo da referência e após a normalização eles ficaram acima. Já no SWIR 2 os valores se afastaram ligeiramente, com destaque para o ano de 2007.

Ao comparar o Gráfico 4.3, que mostra os valores das amostras de gramínea antes da normalização, com o Gráfico 4.4, os valores pós normalização, nota-se que os valores na banda do vermelho dos anos de 1984 e 2007 se aproximaram aos da imagem de referência de 1994, e o valor de 2011 se distanciou um pouco. Na banda do NIR ao contrário, os valores de 1984 e 2007 se afastaram ligeiramente enquanto o de 2011 se aproximou da referência. No SWIR o padrão foi semelhante ao da banda do vermelho.

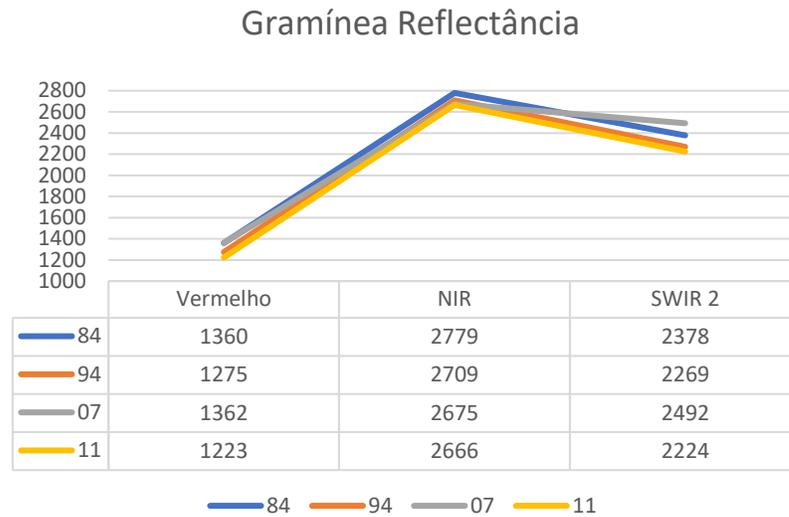


Gráfico 4.3- Amostras de gramínea nas imagens em valor de reflectância

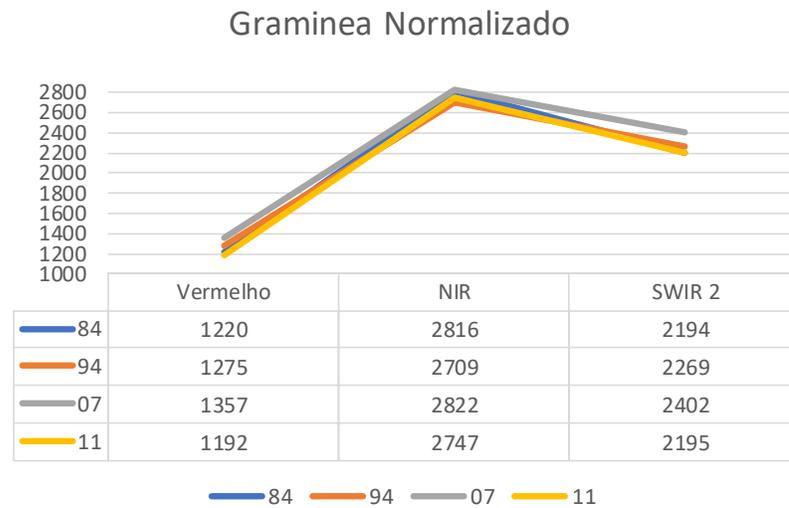


Gráfico 4.4- Amostras de gramínea nas imagens normalizadas

Os gráficos referentes à classe Solo exposto (Gráfico 4.5 e Gráfico 4.6) mostram que na banda do vermelho apenas o ano de 2007 não se aproximou das imagens de 1994, enquanto na banda do NIR todos os anos se afastaram do valor de referência, mas aproximaram-se entre si. Na banda do SWIR 2 todas as bandas tiveram os valores alterados em direção as imagens de 1994.

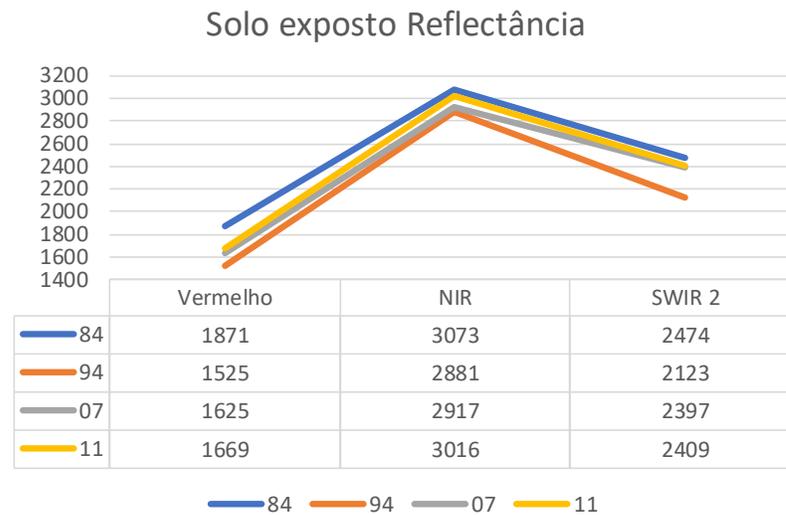


Gráfico 4.5- Amostras de solo exposto nas imagens em valor de reflectância

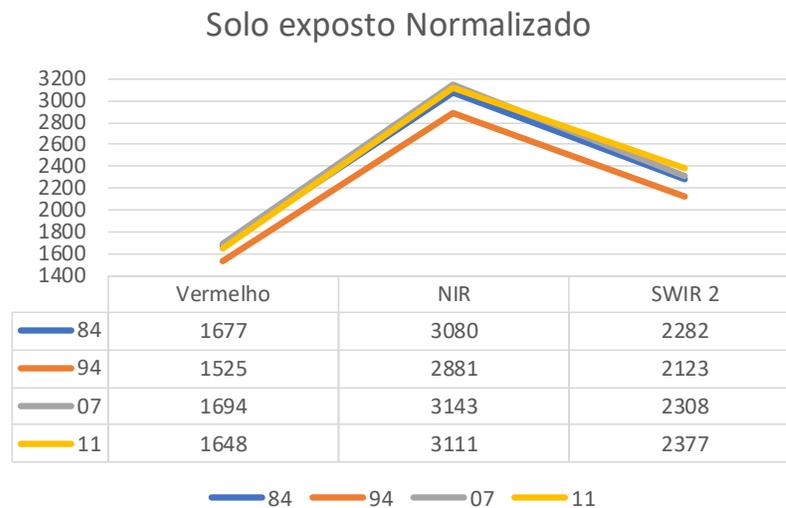


Gráfico 4.6- Amostras de solo exposto nas imagens normalizadas

A análise das amostras dos resultados do processo de normalização indicou uma redução das diferenças espectrais entre as imagens de datas diferentes. Apesar de algumas amostras apresentarem uma diferença maior após a normalização, o resultado como um todo apresentou uma melhora em relação aos dados originais para fins de comparação e detecção de mudanças.

4.2. Quanto à exatidão temática

Como este processo de classificação possui duas abordagens temporais e produz mais de um mapa ao longo da execução, optou-se por fazer a validação em duas partes, avaliando-se:

- a classificação multitemporal, considerando apenas as classes de Mudança e Não Mudança na cobertura florestal ao longo de toda a série histórica; e
- as classificações bitemporais das mudanças, usando todas as classes geradas para cada intervalo.

Há de se considerar que a validação de mapas temáticos que envolvem informações temporais não é uma tarefa simples, pois, muitas vezes, não existe uma fonte de referência com um nível de detalhamento maior para fins de comparação, ou alguma informação confiável. Neste estudo, por se tratar de uma série histórica longa quanto mais antiga é a data da imagem, menos informação está disponível para validar os mapas, estando dependente da interpretação das próprias imagens por especialistas. Já para as imagens recentes existem mais possibilidades de fonte de dados, como o *Google Earth* que disponibiliza a visualização de imagens de desde meados de 2000 em alta resolução.

O índice Kappa junto com a matriz de confusão foram escolhidos como método estatístico de avaliação da exatidão das classificações. Para validação do mapa de Mudança e Não Mudança foram selecionados 120 pontos aleatoriamente, separados igualmente entre as duas classes. Cada ponto foi analisado considerando a representatividade da classe de todo o objeto no qual ele está inserido e não somente do *pixel*. A Tabela 4 com a matriz de confusão do primeiro nível de classificação pode ser observada abaixo.

Tabela 4- Matriz de confusão das classes mudança e não mudança na cobertura florestal

Classe mapeada \ Classe validada	Mudança	Não Mudança	Total
	Mudança	56	4
Não Mudança	2	58	60
Total	58	62	120

Essa classificação apresentou um bom resultado com uma exatidão global de 95% e o índice Kappa de 0,9. A classe Não Mudança teve 6,5% de erro de omissão e 3,3% de erro de comissão, enquanto a classe de mudança apresentou um erro de omissão de 3,4% e de comissão de 6,7%.

Para a validação das classificações bitemporais foi feita uma avaliação para cada intervalo do período. Foram utilizados 120 novos pontos distribuídos entre as cinco classes: Supressão (30), Supressão não florestal (30), Não mudança (60), Regeneração (30) e Regeneração não florestal (30). A distribuição da quantidade de pontos para cada classe foi feita considerando uma possível

análise agregando as classes de Supressão e Supressão não florestal, e Regeneração e Regeneração não florestal de modo a obter uma distribuição igual entre as classes ao agregá-las. Abaixo pode ser observado a matriz de confusão da classificação referente ao período de 1984 a 1994.

Tabela 5- Matriz de confusão do período de 1984 a 1994

Classe validada Classe mapeada	Supressão	Supressão não florestal	Não mudança	Regeneração	Regeneração não florestal	Total
Supressão	26	4	0	0	0	30
Supressão não florestal	3	27	0	0	0	30
Não mudança	1	3	51	1	4	60
Regeneração	0	0	0	20	10	30
Regeneração não florestal	0	0	0	1	29	30
Total	30	34	51	22	43	

A classificação desse período apresentou uma exatidão global de 85% e um índice Kappa de 0,8. Os erros de comissão e omissão podem ser observados na tabela a seguir.

Tabela 6- Erros de omissão e comissão no período de 1984 a 1994

Classe	Omissão (%)	Comissão (%)
Supressão	13,3	13,3
Supressão não florestal	20,6	10
Não mudança	0	15
Regeneração	9,1	33,3
Regeneração não florestal	32,6	3,3

Os maiores erros de omissão foram nas classes de Supressão não florestal e Regeneração não florestal com 20,6% e 32,6%, respectivamente. A maior parte da confusão foi referente às classes de Supressão e Regeneração respectivamente. A classe Não Mudança não apresentou erro de omissão, mas obteve erro de comissão de 15%, o que significa que ela foi ligeiramente superestimada incluindo principalmente as classes de Regeneração não florestal e Supressão não florestal.

Abaixo pode ser analisado a matriz de confusão referente ao período de 1994 a 2007.

Tabela 7- Matriz de confusão do período de 1994 a 2007

Classe validada Classe mapeada	Supressão	Supressão não florestal	Não mudança	Regeneração	Regeneração não florestal	Total
Supressão	24	6	0	0	0	30
Supressão não florestal	4	26	0	0	0	30
Não mudança	0	2	56	0	2	60
Regeneração	0	0	2	23	5	30
Regeneração não florestal	0	0	0	2	28	30
Total	28	34	58	25	35	

Este período apresentou uma exatidão global de 87,2% e um índice Kappa de 0,83. Os erros de omissão e comissão podem ser analisados na tabela abaixo.

Tabela 8- Erros de omissão e comissão no período de 1994 a 2007

Classe	Omissão (%)	Comissão (%)
Supressão	14,3	20
Supressão não florestal	23,5	13,3
Não mudança	3,4	6,7
Regeneração	8	23,3
Regeneração não florestal	20,0	6,7

Neste período as classes que mais se confundiram foram Regeneração com Regeneração não florestal e Supressão com Supressão não florestal. O maior erro de comissão foi de Supressão não florestal com 23,5% e o de comissão foi o de Regeneração com 23,3%.

A matriz de confusão do período de 2007 a 2011 pode ser observada abaixo. Nesse período não foi possível distribuir os pontos igualmente entre as classes, pois foi um período estável, sem muitas mudanças significativas. A classe Supressão só teve 13 objetos identificados, onde foram todos avaliados, e para compensar incluímos os pontos faltantes para a classe Supressão não florestal, que obteve um total de 47 pontos.

Tabela 9- Matriz de confusão do período de 2007 a 2011

Classe validada Classe mapeada	Supressão	Supressão não florestal	Não mudança	Regeneração	Regeneração não florestal	Total
Supressão	4	9	0	0	0	13
Supressão não florestal	3	41	3	0	0	47
Não mudança	0	0	59	1	2	60
Regeneração	0	0	0	22	8	30
Regeneração não florestal	0	0	3	0	27	30
Total	7	50	65	23	37	

Este período obteve uma exatidão global de 85% e um índice Kappa de 0,8. A tabela com os erros de omissão e comissão pode ser observado abaixo.

Tabela 10- Erros de omissão e comissão no período de 2007 a 2011

Classe	Omissão (%)	Comissão (%)
Supressão	42,9	69,2
Supressão não florestal	18,0	12,8
Não mudança	9,2	1,7
Regeneração	4,3	26,7
Regeneração não florestal	27,0	10,0

Neste caso, a supressão apresentou erros altos de omissão e comissão com 42,9% e 69,2%, respectivamente. Isso se deu pela baixa quantidade de amostras e em uma classe de baixa expressividade no período. A maioria das confusões também se deram entre os tipos de Supressão e Regeneração e a classe de Não Mudança só foi confundida com os dois tipos de Regeneração.

4.3. Quanto à classificação

A bacia hidrográfica do rio São João possui uma área total 2.115 Km². Entre 1984 e 2011 aproximadamente 628 Km² (30%) se mantiveram como cobertura florestal inalterada e 230 Km² (10%) apresentaram algum tipo de mudança, relacionada a este tipo de cobertura, e 1.257 Km² (60%) foram classificadas como coberturas não florestais (Figura 4.1).

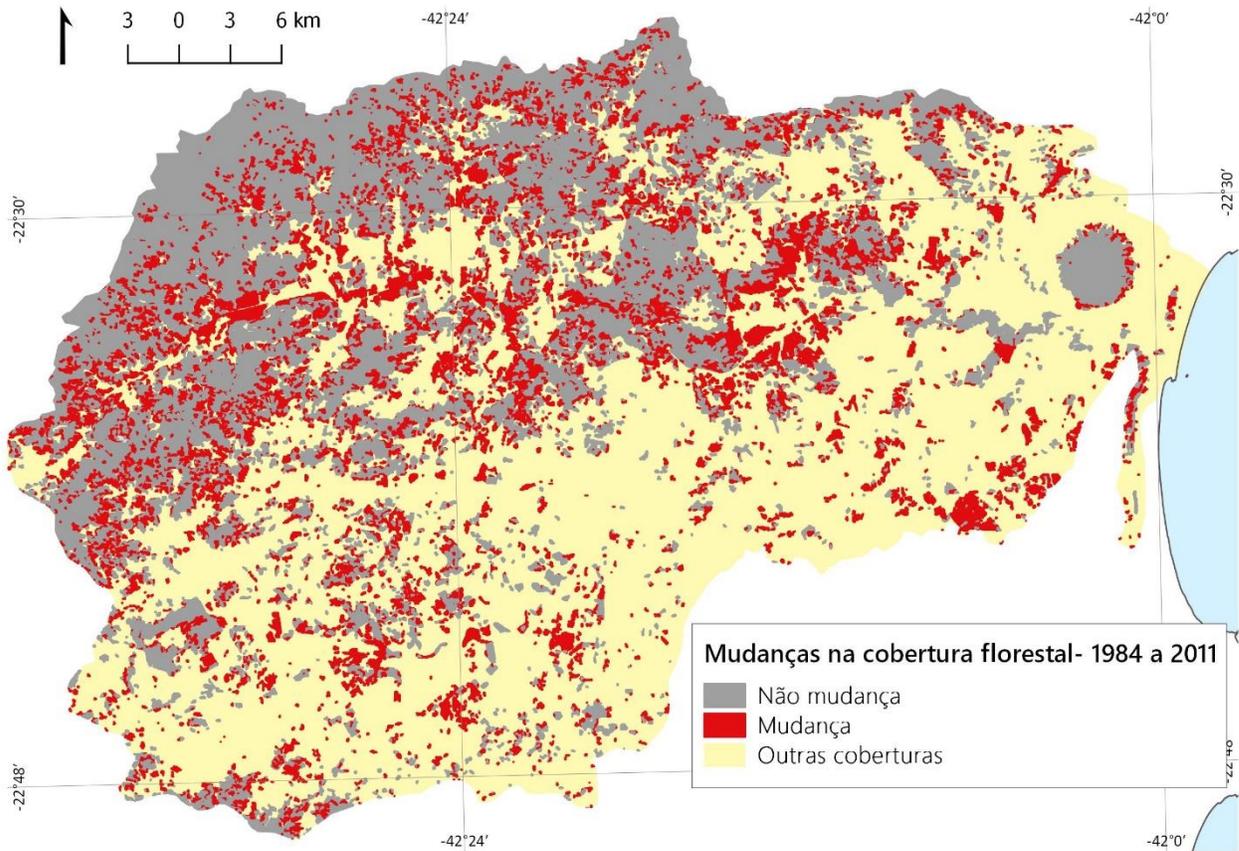


Figura 4.1- Mapa com as mudanças e não mudanças considerando a série histórica de 1984 a 2011. Datum: Sirgas 2000

As análises dos 8% de mudança serão apresentados a partir de duas perspectivas: bitemporal, observando as mudanças em cada intervalo de ano, e multitemporal, considerando as mudanças ao longo de toda a trajetória.

4.3.1. Por intervalo

Os períodos classificados na série histórica foram de 1984 a 1994; 1994 a 2007 e 2007 a 2011. Para analisar esses três intervalos separadamente foi necessário criar um novo arquivo para cada período, pois o resultado final da metodologia apresenta um único vetor com as delimitações detalhadas de toda a série histórica com as classes de cada intervalo separadas em colunas na tabela de atributos. Este vetor, no formato *shapefile*, foi simplificado usando a ferramenta ‘dissolve’, que une os segmentos contíguos de classes iguais de uma determinada coluna. Esta ferramenta foi executada três vezes, uma para cada período estudado. Com isso, formaram-se objetos que

representam cada classe como uma entidade única para os períodos separadamente, permitindo, assim, analisa-los de acordo com cada temporalidade.

4.3.1.1. De 1984 a 1994

Este período foi o que apresentou as mudanças mais significativas na área de estudo. Dos 230 km² de possíveis mudanças ocorridas em cobertura florestal durante toda a série histórica, 97 km² permaneceram inalterados e 133 km² apresentaram algum tipo de alteração (Figura 4.2). Por ser o intervalo mais antigo, era esperado apresentar as maiores mudanças dessa série histórica, pois a Mata Atlântica como um todo sofreu suas principais supressões antes de 1984, em um período onde era difícil o registro dessas alterações.

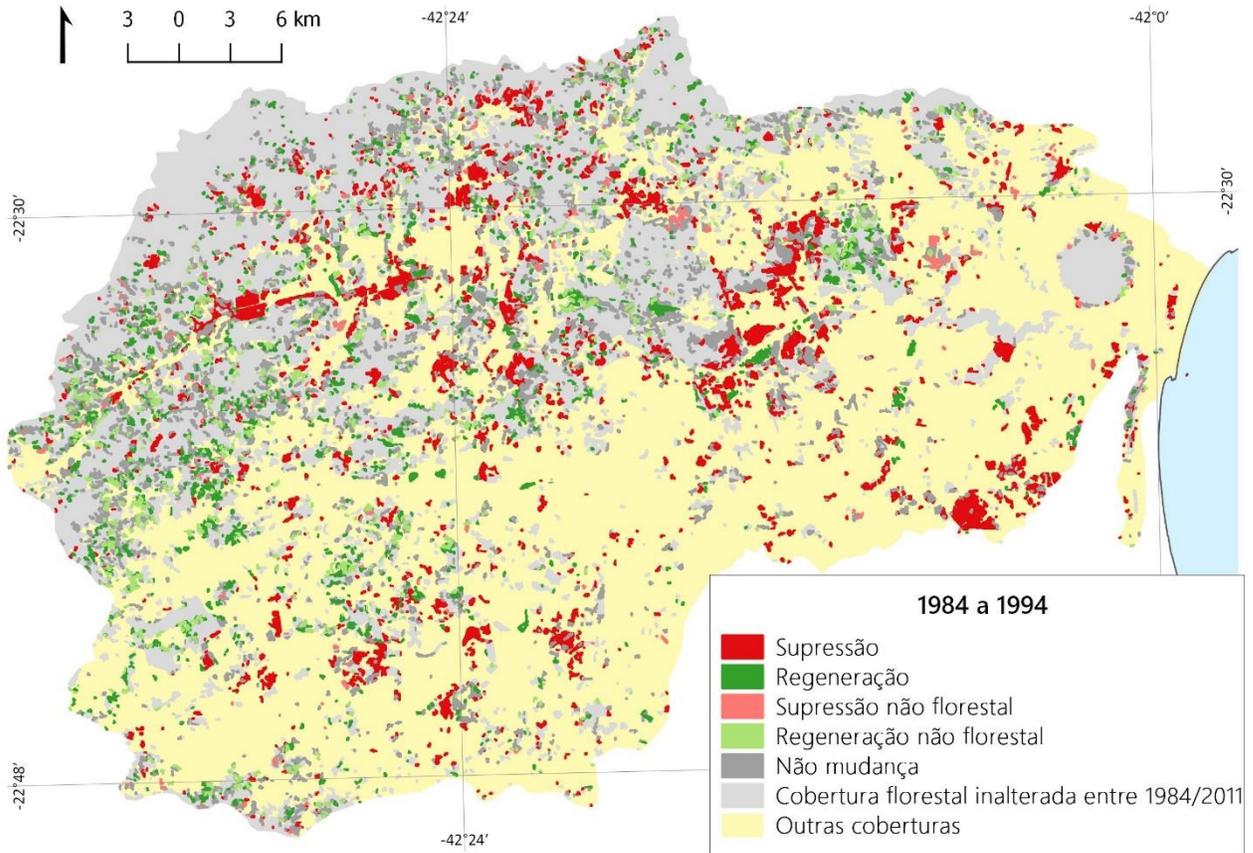


Figura 4.2- Mapa de mudanças na cobertura florestal entre 1984 e 1994. Datum: SIRGAS 2000

Das áreas que apresentaram mudanças, 77 km² foram de supressão e 33 km² de regeneração da cobertura florestal (Gráfico 4.7). A supressão representou 58% das mudanças ocorridas no

período, mais que o dobro da regeneração, que obteve 25%. Já as mudanças em coberturas não florestais corresponderam a 17% da área total de mudanças.

ÁREA TOTAL (KM²) POR CLASSE DE MUDANÇA 1984-1994

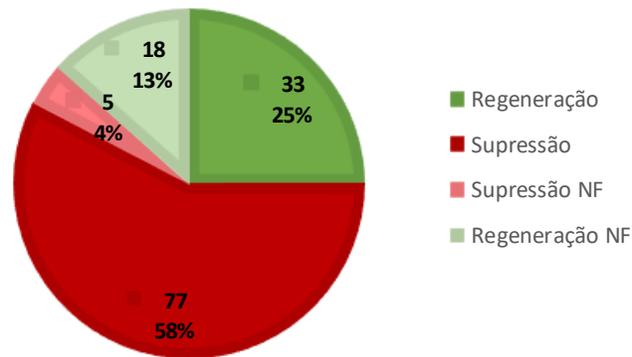


Gráfico 4.7- Área total (Km²) das classes Supressão, Regeneração e mudanças Não Florestais entre 1984 e 1994

Encontraram-se 3.446 objetos referentes às mudanças neste período, onde 38% representam a supressão e 34% a regeneração. Isso indica que a supressão apresentou objetos de maiores que as outras classes, pois mesmo tendo mais que o dobro de área total que a regeneração o número de objetos encontrados é muito próximo (Gráfico 4.8). Já na classe Regeneração Não Florestal a situação se inverte, uma área bem menor (18 Km²) é distribuída em uma grande quantidade de objetos (744), resultando em objetos menores e mais distribuídos.

NÚMERO DE OBJETOS POR CLASSE DE MUDANÇA 1984-1994

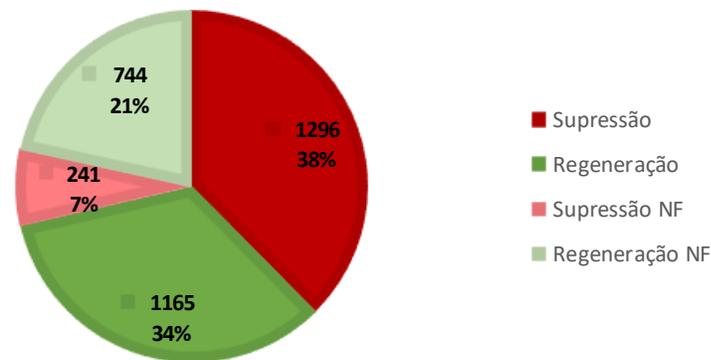


Gráfico 4.8- Número de objetos por classes de Supressão, Regeneração e mudanças Não Florestais entre 1984 e 1994

Isso se comprova ao observar o tamanho médio dos objetos por classe e os respectivos desvio padrão (Gráfico 4.9). A Supressão apresentou um tamanho médio de 6 hectares, mais de duas vezes maior do que as outras classes, e um alto desvio padrão, em função de alguns objetos de tamanho maior do que a média geral.

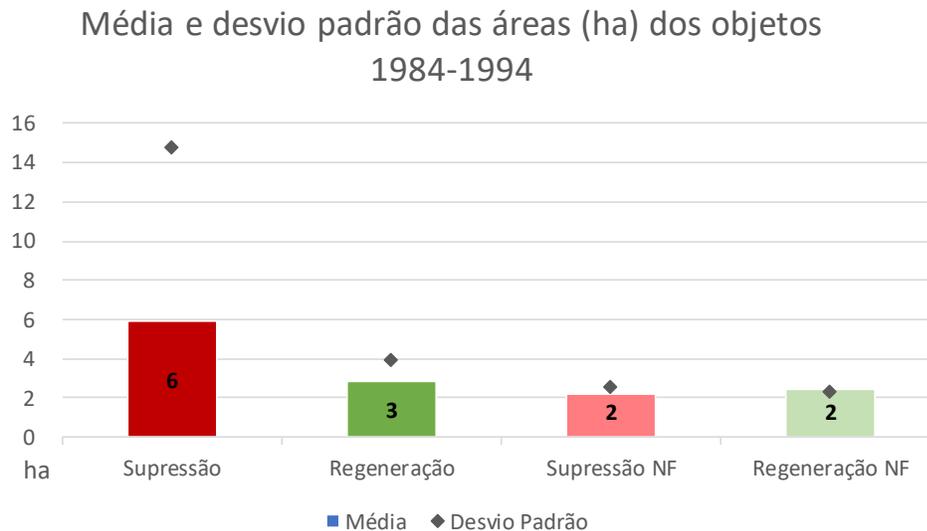


Gráfico 4.9- Média e Desvio padrão das áreas(hectares) dos objetos entre 1984 e 1994

Os objetos de mudança foram cruzados com o mapa de declividade da bacia para caracterizar as ocorrências de acordo com o relevo. As classes de declividade foram definidas em graus usando os critérios de SEABRA (2012) com os seguintes intervalos: 0-3; 3-6; 6-12; 12-24; 24-45 e > 45. Para cada intervalo de declividade foi contabilizada a frequência dos objetos e a área total de cada classe de mudança.

A classe de supressão apresentou maior ocorrência em áreas de baixas declividades (0-3 e 3-6) com quase 50 km², distribuídos em 637 objetos (Gráfico 4.10). Na declividade 3-6 encontrou-se os maiores objetos de supressão com uma relação área/frequência mais alta, enquanto objetos menores foram verificados na classe 12-24, pois percebe-se uma alta frequência de objetos para uma área total mais baixa. Com isso, o padrão de supressão desse período foi caracterizado por objetos maiores em baixas declividades, e objetos menores em média declividade.

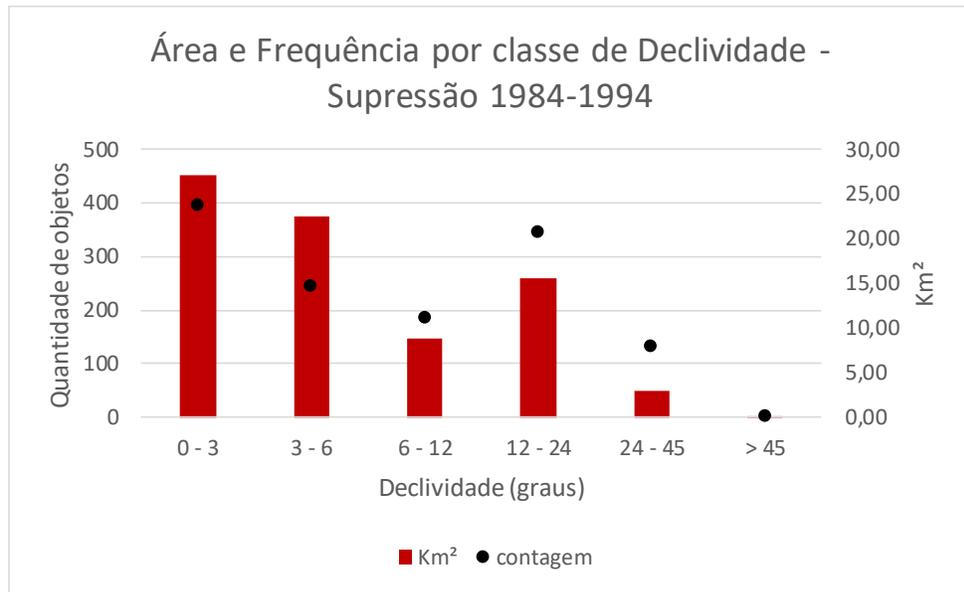


Gráfico 4.10- - Área e frequência de supressão por classe de declividade entre 1984-1994

Com relação à regeneração no período, observou-se uma maior incidência em áreas de declividade entre 12 e 24 graus com a presença de objetos maiores em comparação as ocorrências em outras classes de declividade (Gráfico 4.11).

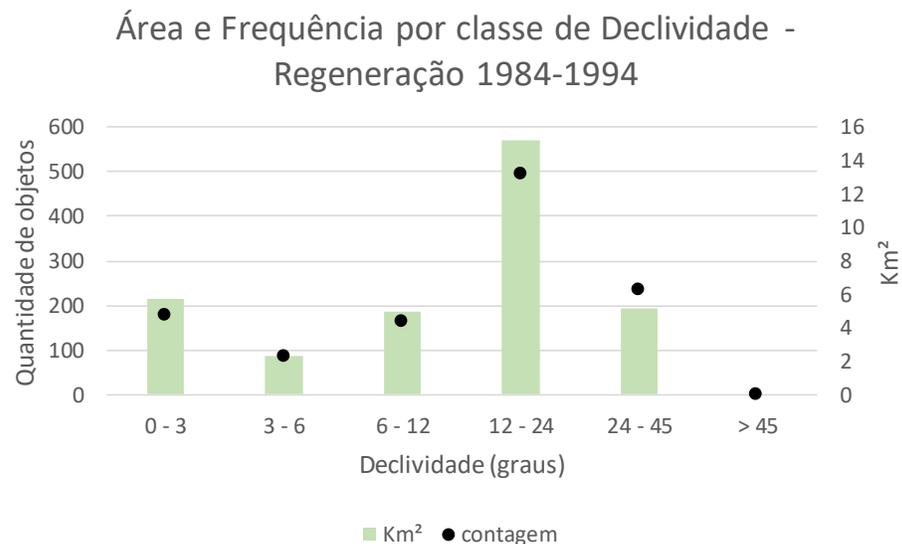


Gráfico 4.11- - Área e frequência de regeneração por classe de declividade entre 1984-1994

Na área de estudo existe uma alta correlação entre baixa declividade e baixas altitudes, consequentemente, as maiores áreas de supressão ocorreram em baixa altitude. Já a supressão

apresentou uma maior quantidade de objetos na faixa de altitude entre 40 a 200 metros (Gráfico 4.12).

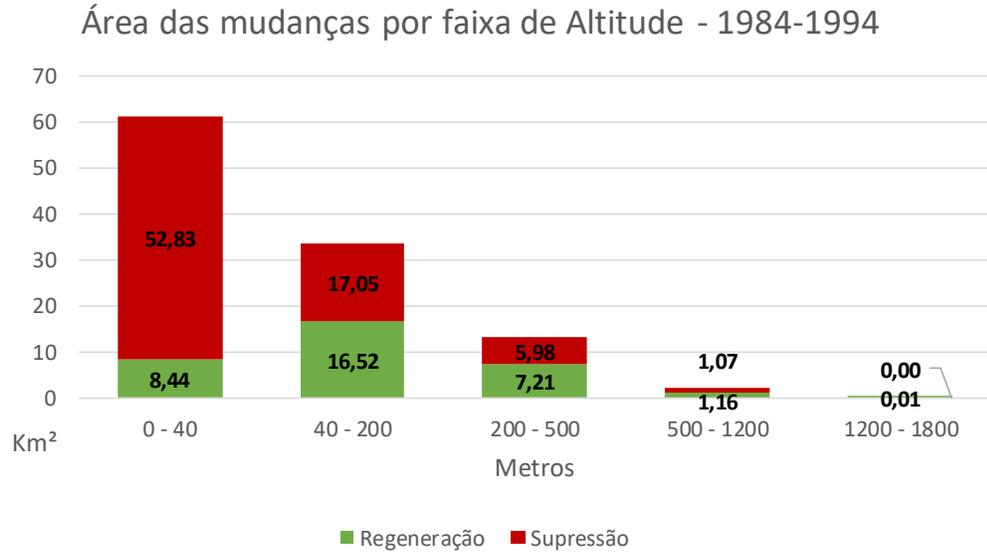


Gráfico 4.12- Áreas das mudanças por faixa de altitude entre 1984-1994

4.3.1.2. 1994-2007

No período de 1994 a 2007 as alterações na cobertura florestal tiveram um padrão diferente do intervalo anterior, com uma diminuição significativa de área total de mudanças e uma alteração nas áreas de ocorrências. Neste caso, ocorreram alterações na cobertura florestal em 71 km² da bacia, uma diminuição de quase metade da área em comparação ao período anterior, e cerca de 159 km² se mantiveram estáveis considerando apenas as áreas de possíveis mudanças identificadas em toda série histórica (Figura 4.3).

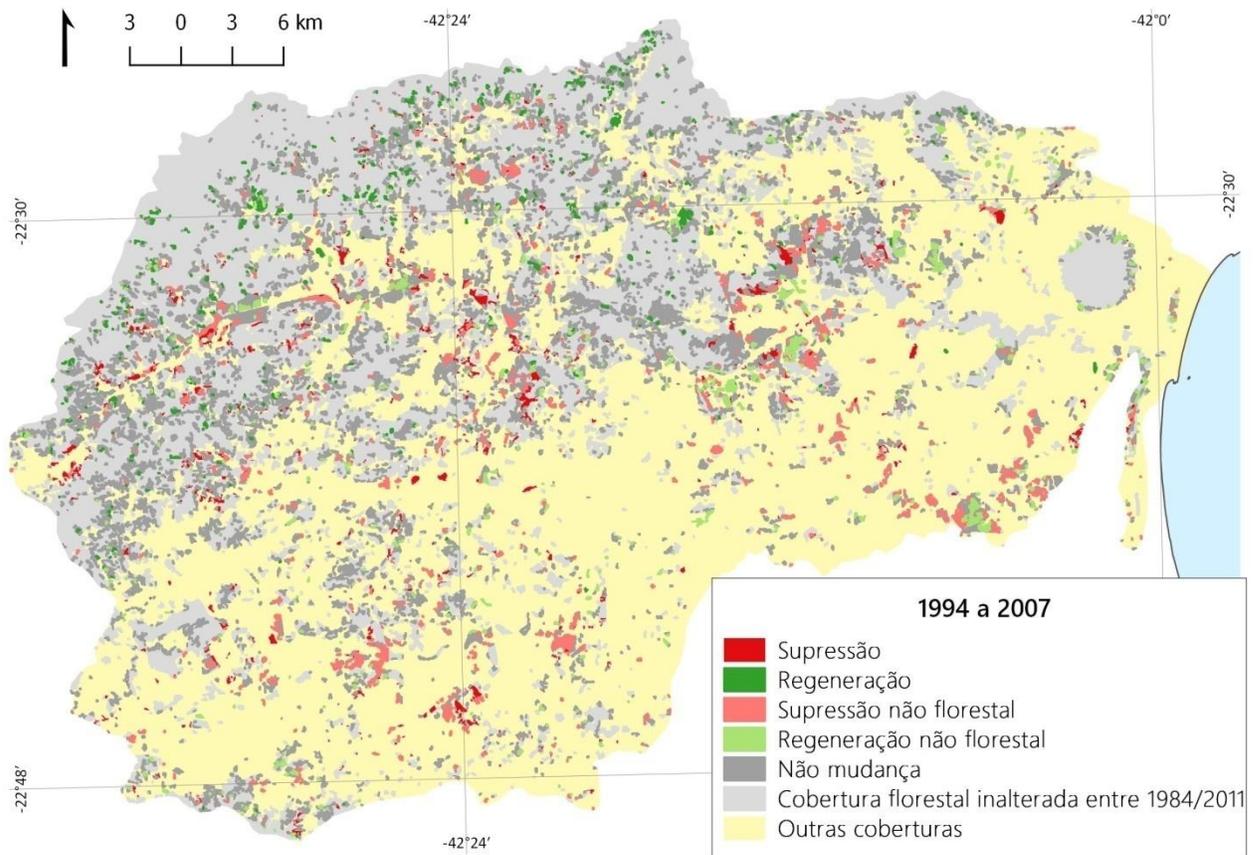


Figura 4.3- Mapa de mudanças na cobertura florestal entre 1994 e 2007. Datum: SIRGAS 2000

Dos 71 km² de mudanças identificadas entre 1994 e 2007, a supressão representou 38% totalizando 27 km², enquanto foram regeneradas cerca de 13 km², 18% das áreas com alterações (Gráfico 4.13). Houve um aumento significativo nas áreas de supressão não florestada em relação ao período anterior passando de 5 km² para 23 km², isso pode estar relacionado à dinâmica da agricultura, onde na imagem de 1994 há a presença de áreas cultivadas em estágios mais avançados, com uma biomassa mais presente, enquanto na imagem de 2007 essas áreas já foram colhidas ou já estão em uma fase inicial apresentando menor biomassa. Já as áreas de regeneração não florestal apresentaram uma pequena diminuição em relação ao período anterior.

**ÁREA TOTAL (KM²) POR CLASSE DE MUDANÇA
1994-2007**

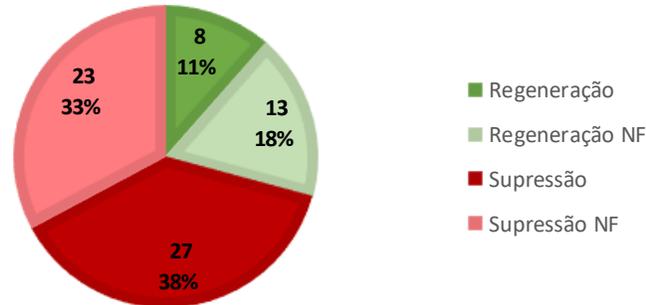


Gráfico 4.13- Área total (km²) por classes de Supressão, Regeneração e mudanças Não Florestais entre 1994 e 2007

Com relação ao número de objetos (Gráfico 4.14), identificou-se 2.096, dos quais 658 referentes à supressão (31%) e 417 de regeneração (20%). Percebe-se que tanto na área total quanto no número de objetos há uma proporção meio a meio entre mudanças florestais e não florestais. Porém, os tamanhos desses objetos variam entre as classes.

**NÚMERO DE OBJETOS POR CLASSES DE MUDANÇA
1994-2007**

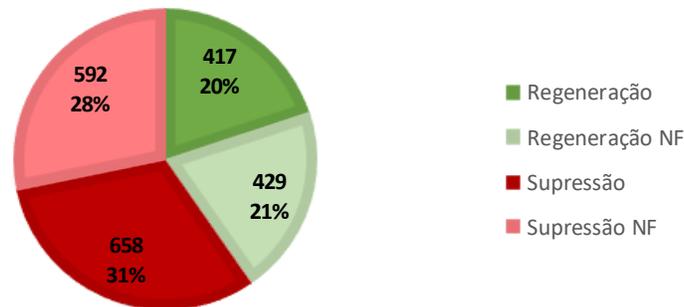


Gráfico 4.14- Número de objetos por classes de Supressão, Regeneração e mudanças Não Florestais entre 1994 e 2007

Ao observar o Gráfico 4.15, que mostra o tamanho médio e desvio padrão de cada classe, percebe-se que os maiores objetos foram encontrados na supressão e supressão não florestal com uma média aproximada de 4 hectares e alto desvio padrão. A regeneração não florestal também possui um alto desvio padrão, porém com um tamanho médio menor, enquanto a regeneração apresentou um baixo tamanho médio e desvio padrão. As classes de mudanças não florestal

apresentaram um aumento no tamanho médio e desvio padrão dos objetos em relação ao período anterior, enquanto que regeneração e supressão tiveram uma diminuição em ambas as estatísticas. A supressão manteve a classe com maiores objetos neste intervalo, porém com tamanhos menores em comparação ao intervalo anterior.

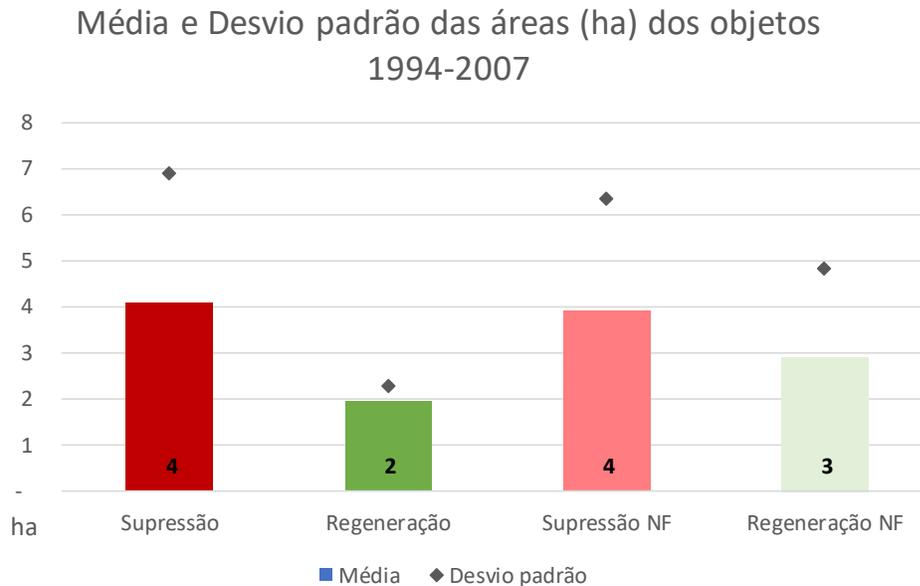


Gráfico 4.15- Média e desvio padrão das áreas (hectares) dos objetos entre 1994 e 2007

O período entre 1994 e 2007 mostrou uma distribuição da classe de supressão em faixas de declividade parecida com o intervalo anterior, porém com um quantitativo significativamente menor. A principal diferença está na classe de declividade entre 3 e 6 graus que apresentou uma maior diminuição proporcionalmente a outras categorias e uma relação área/frequência menor. Neste caso, a supressão nesta categoria apresentou menor área que na classe de 12 a 24 graus, invertendo as posições comparando com o intervalo de 1984 e 1994, e se aproximando do valor da categoria de 6 a 12 graus, onde, anteriormente, ela apresentava o dobro de área.

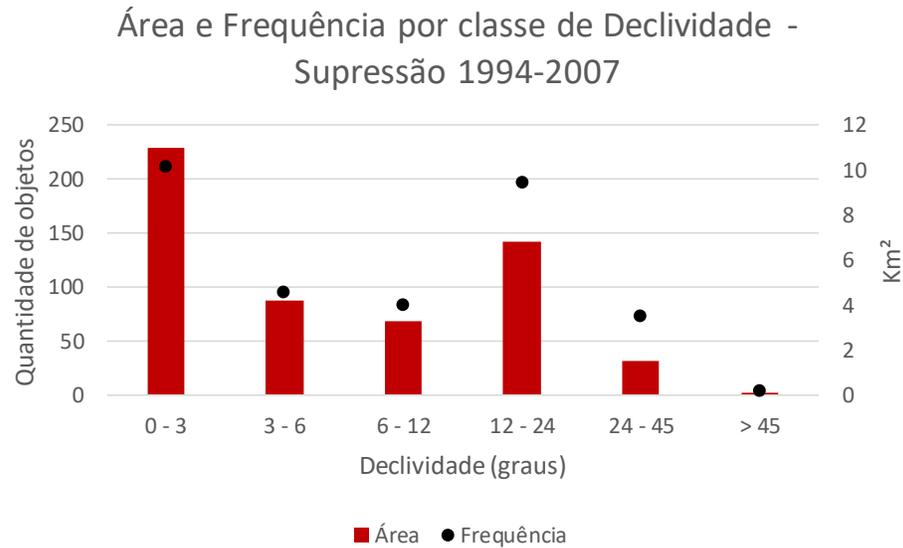


Gráfico 4.16- Área e frequência de supressão por classe de declividade entre 1994-2007

A classe de regeneração também manteve o mesmo padrão de distribuição entre as categorias só que uma área total menor (Gráfico 4.17). Neste caso, a categoria de declividade que se diferenciou do período anterior foi a de 24 a 45 graus que superou todas as outras categorias, com exceção de 12 a 24 que se manteve como a que obteve maior área de regeneração.

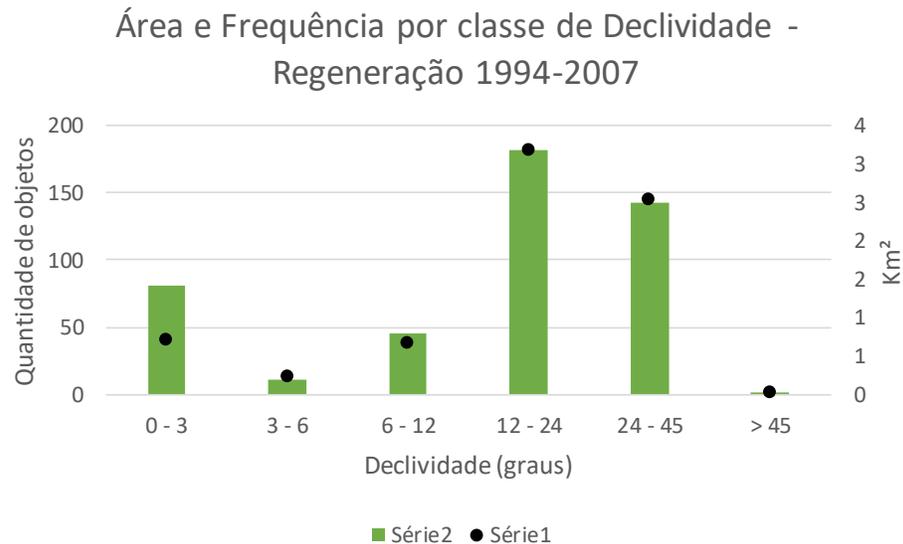


Gráfico 4.17- Área e frequência de regeneração por classe de declividade entre 1994-2007

Com relação às faixas de altitude, não houve mudança no padrão de distribuição de área entre as classes, apenas a diminuição no total de área (Gráfico 4.18).

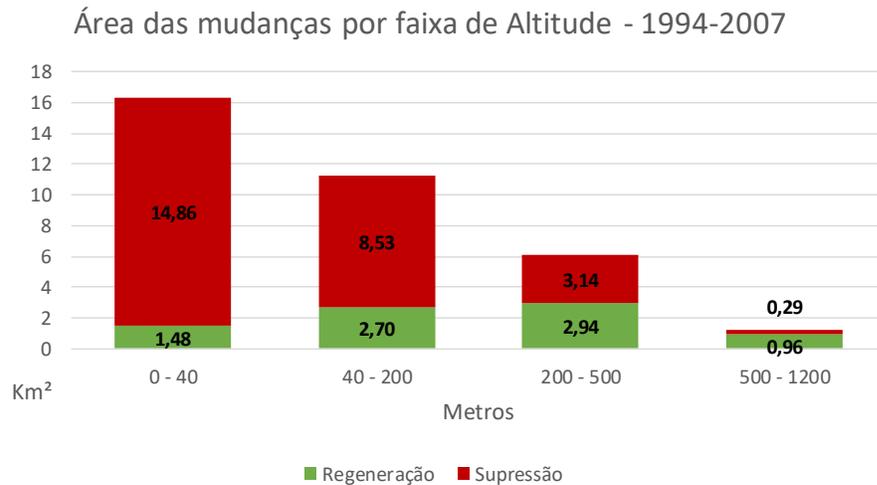


Gráfico 4.18- Área das mudanças por faixa de altitude entre 1994-2007

4.3.1.3. 2007 a 2011

O período entre 2007 e 2011 foi o mais curto entre os três analisados em função da limitação da série do sensor TM que foi desativado em 2011. Durante esse intervalo houve poucas mudanças significativas na cobertura florestal (Figura 4.4). A bacia do rio São João apresentou uma estabilização na dinâmica florestal ao longo dos períodos analisados anteriormente, e este, por ser mais curto, era esperado uma menor área de mudanças. Apenas 28 km² apresentaram algum tipo de alteração, a maior parte referentes às mudanças não florestais, e 102 km² permaneceram inalterados dentre os 230 km² de possíveis alterações na série histórica.

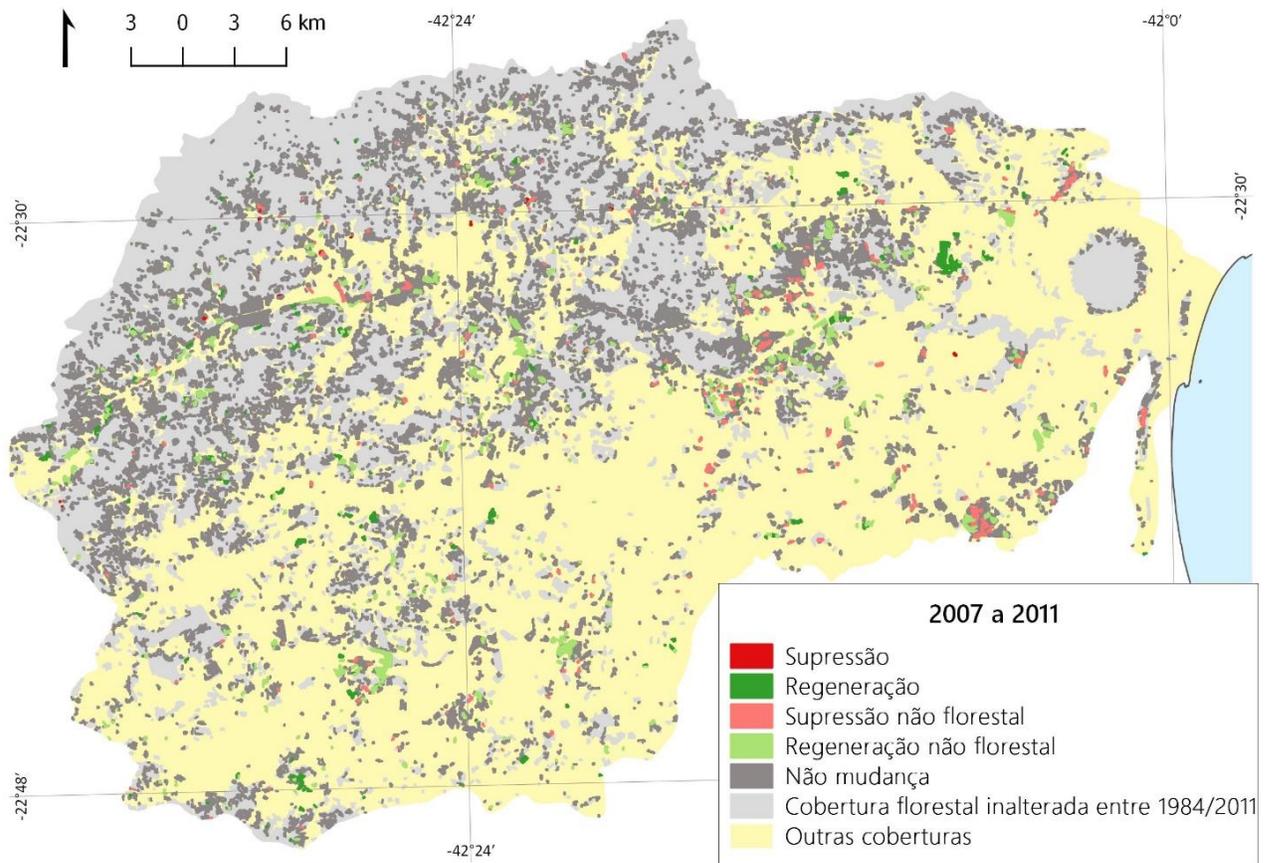


Figura 4.4- Mapa de mudanças na cobertura florestal entre 2007 e 2011. Datum: SIRGAS 2000

A regeneração não florestal obteve a maior área com aproximadamente 16 km², representando mais da metade das mudanças no período, seguido da supressão não florestal com 6 km² (Gráfico 4.19). A regeneração apresentou cerca de 6 km², com 20% da área total de mudanças, sendo o único tipo de mudança significativa no período, ressaltada pela expansão da silvicultura. A supressão foi desconsiderada nessa análise pois, além da baixa ocorrência, durante o processo de validação todos os objetos dessa classe foram invalidados.

**ÁREA TOTAL (KM²) POR CLASSE DE MUDANÇA
2007-2011**

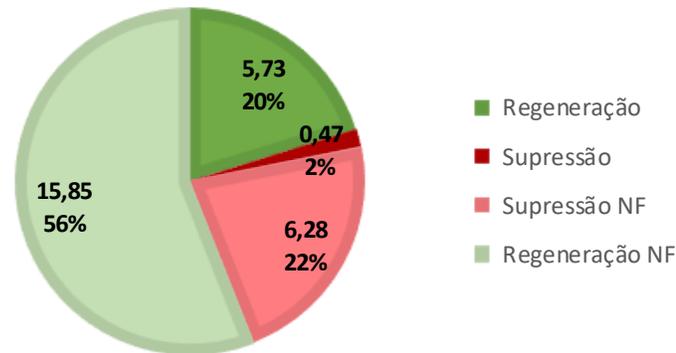


Gráfico 4.19- Área total (km²) por classe de mudança 2007-2011

Com relação ao número de objetos por classe (Gráfico 4.20), percebe-se uma distribuição proporcional aos valores de área total, porém com uma pequena diminuição nos valores das duas classes de regeneração e um leve aumento na classe de supressão não florestal.

**NÚMERO DE OBJETOS POR CLASSES DE MUDANÇA
2007-2011**

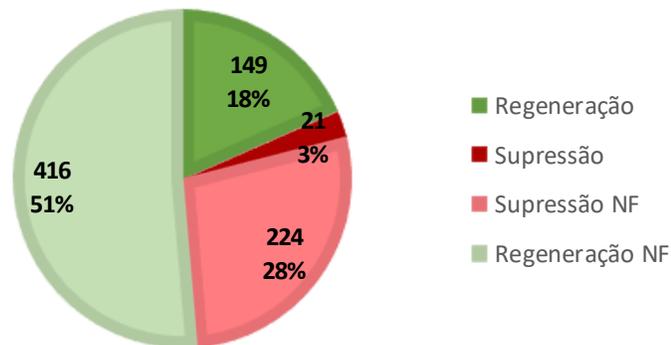


Gráfico 4.20- Número de objetos por classe de mudança 2007-2011

Isto indica a presença de objetos maiores nas classes de regeneração e é confirmado no Gráfico 4.21, com os valores médios de 4 hectares e um alto desvio padrão, enquanto a classe de supressão não florestal apresentou um tamanho médio de 3 hectares e baixo desvio padrão. Os grandes objetos da classe regeneração estão relacionados com o cultivo de eucalipto na área, que vem crescendo no estado do Rio de Janeiro nos últimos anos.

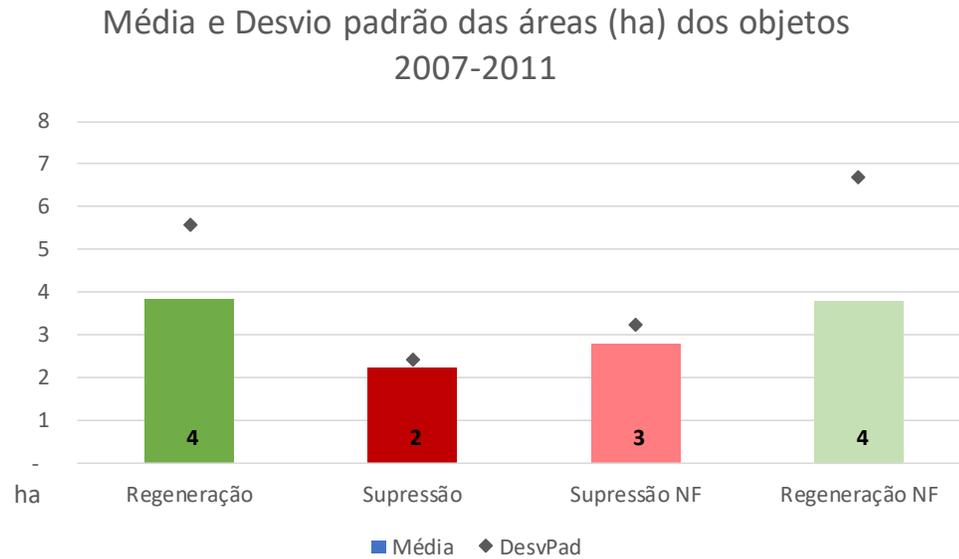


Gráfico 4.21- Média e desvio padrão das áreas (hectares) dos objetos entre 2007-2011

Os objetos maiores da classe de regeneração não florestal estão associados à agricultura em grandes lotes, principalmente nas áreas mais planas, como pode ser observado no Gráfico 4.22. A classe entre 0 e 3 graus se destaca com a maior área entre elas. Percebe-se, também, nessa classe e na de 3 a 6 graus que a relação frequência e área de ambas indicam a presença de objetos maiores.

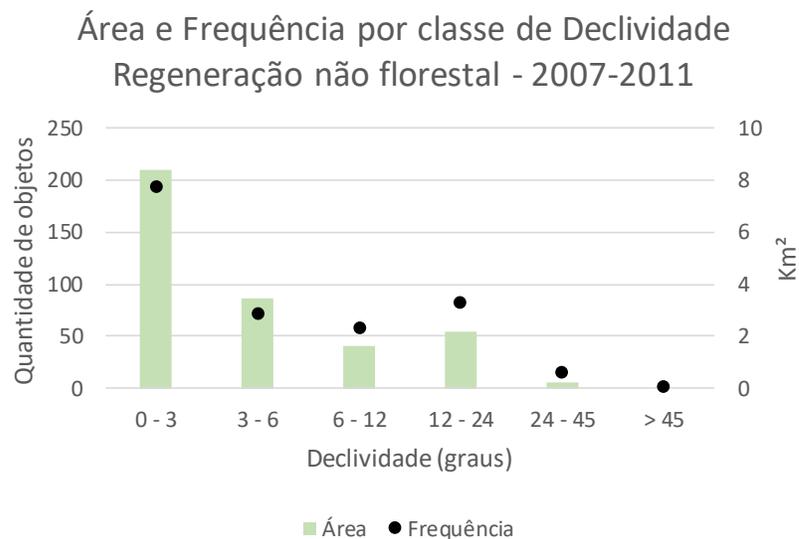


Gráfico 4.22-Área e frequência de regeneração não florestal por classe de declividade entre 2007 e 2011

A faixa de declividade com maior presença de regeneração foi a de 6 a 12 graus com cerca de 2,5 km². Nesta categoria de declividade também foram encontrados os maiores objetos dessa

classe e em menor quantidade, como pode ser observado no Gráfico 4.23 a baixa frequência de objetos e maior área. Já nas áreas planas, entre 0 e 3 graus, a regeneração se apresentou em fragmentos menores, mas em maior quantidade.

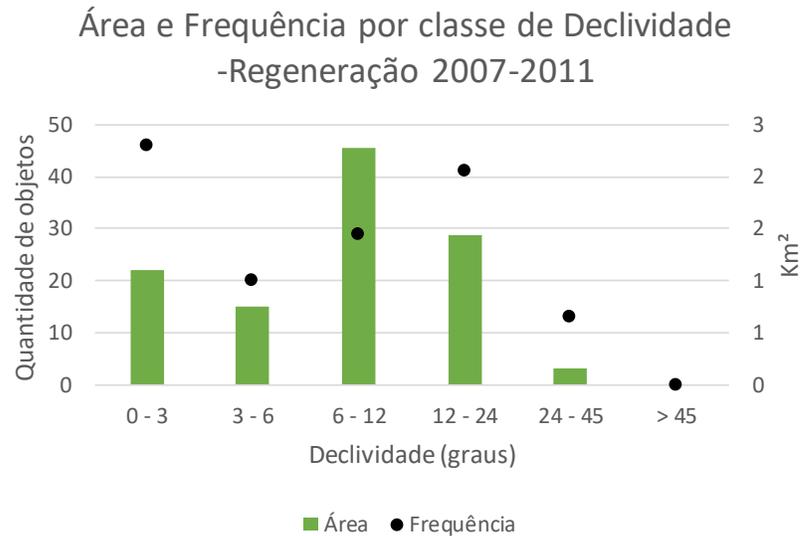


Gráfico 4.23- Área e frequência de regeneração por classe de declividade entre 2007 e 2011

Com relação às ocorrências das regenerações por faixa de altitude (Gráfico 4.24), houve uma concentração em áreas de até 200 metros de altitude, principalmente até 40 metros. A classe regeneração se dividiu entre as categorias de 0 a 40 e 40 a 200 metros, enquanto a regeneração não florestal teve sua maior área na faixa de 0 a 40 com quase 12 km².

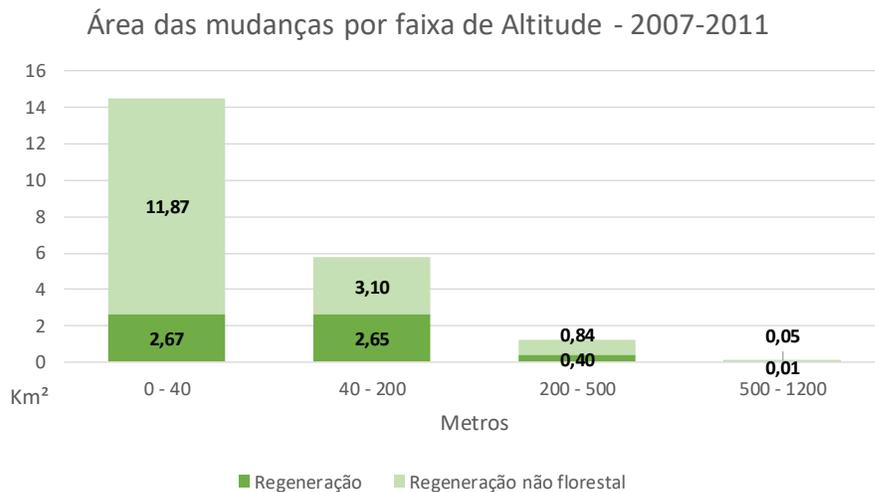


Gráfico 4.24- Área das mudanças por faixa de altitude entre 2007 e 2011

Percebe-se que ao longo do período há uma diminuição na intensidade das mudanças, com valores de área cada vez menores e uma inversão na predominância de supressão para regeneração no último período. No Gráfico 4.25 nota-se um declínio considerável da supressão ao longo da série. Se inicia com um valor alto de 77 km² entre 1984 e 1994 e passa para 27 km² no período seguinte, uma diminuição de quase 2/3, e chega a praticamente zero entre 2007 e 2011. Essa dinâmica pode estar relacionada às políticas públicas voltadas para fiscalização e conservação adotadas a partir dos anos 1990, como o reconhecimento da Mata Atlântica como Reserva da Biosfera e a criação da Área de Proteção Ambiental do rio São João no início dos anos 2000. A regeneração também apresentou um declínio considerável no primeiro intervalo passando de 33 km² para 8 km², quantitativamente menor que a supressão, porém proporcionalmente maior, com uma diminuição de aproximadamente 3/4. Já entre 2007 e 2011 esse valor foi de aproximadamente 6 km², bem próximo do período anterior, e considerando ser o intervalo mais curto pode-se dizer que o processo de regeneração continuou ativo. Essa atividade foi impulsionada pela expansão da silvicultura, o que pode ser verificado através das imagens de alta resolução do *Google Earth* que abrangem essa faixa temporal.

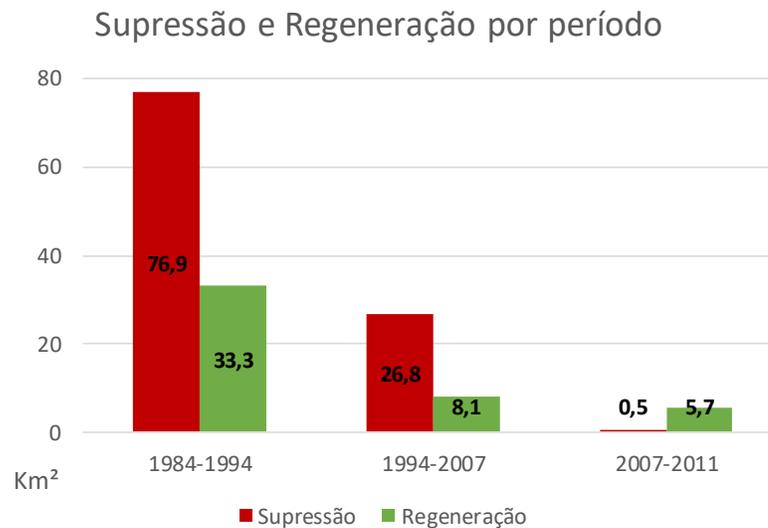


Gráfico 4.25- Supressão e regeneração por período analisado

4.3.2. Pela trajetória

Para a análise dos resultados considerando a trajetória das mudanças ao longo da série histórica foi utilizado apenas o arquivo vetorial final, produto do processo de classificação. Este

vetor possui uma topologia única para os três períodos, com os objetos dispostos em uma configuração que representa as mudanças em toda série histórica, e as informações das classes de cada período separadas por colunas na tabela de atributos. Assim, é possível classificar cada objeto de acordo com sua trajetória, concatenando as classes de cada período e criando, assim, uma tipologia. Por exemplo, um objeto florestal pode ter sido suprimido entre 1984 e 1994, não se alterado entre 1994 e 2007 e se regenerado entre 2007 e 2011, correspondendo a um tipo de trajetória. Como cada um dos 3 intervalos possuem 5 classes, existem 125 trajetórias possíveis para os objetos, onde alguns são improváveis, por exemplo a ocorrência de supressão nos três períodos. Neste estudo de caso foram detectados 74 tipos de trajetórias nos objetos, e por conta dessa grande quantidade se fez necessário agregá-las ou desconsiderá-las de acordo com a definição de critérios que ajudasse a representar as informações. Foram escolhidos dois critérios para agregá-las: um simplificado, utilizando apenas as classes de supressão, regeneração e não mudança, e outro mais detalhado, considerando todas as classes de mudanças e analisando caso a caso os tipos de trajetória para agregá-las levando em consideração a significância das mudanças e a área de abrangência.

4.3.2.1. Critério simplificado

Neste critério, as classes supressão não florestal e regeneração não florestal foram consideradas como não mudança para realçar somente as mudanças em coberturas florestais, reduzindo assim, para 3 classes por período e 27 trajetórias possíveis. Foram encontrados 19 tipos de trajetória na área de estudo entre 1984 e 2011. Foram calculadas as áreas para cada tipo de trajetória e organizadas na Tabela 11 e ordenadas do maior valor para o menor e em seguida rotuladas de 1 a 19. A trajetória que apresenta não mudança nos três períodos, apesar de ser a de maior ocorrência, foi rotulada como 19 pois ela representa áreas inalteradas que não foram classificadas na primeira etapa de classificação, onde foi usado um modelo mais amplo para garantir que as nenhuma área de mudança ficasse de fora. Em seguida foram calculados os valores percentuais das trajetórias de mudança desconsiderando a trajetória 19 (áreas inalteradas). Também foi criado um índice para caracterizar o “saldo” da trajetória, isto é, se ao final da trajetória houve mais regeneração ou supressão. Para isso, considerou para a classe de supressão o valor -1, para mudança o valor 0 e para regeneração o valor 1, e somou-se esses valores de acordo com as classes de trajetória. Se o índice resultar em um valor positivo significa que aquela trajetória resultou em

regeneração florestal, se o valor for negativo indica que a trajetória resultou em supressão, e ser o índice for zero é porque ao final da trajetória a regeneração e supressão se compensaram.

Tabela 11- Trajetórias das mudanças

Trajetória	1984-1994	1994-2007	2007-2011	km ²	%(mudanças)	Índice
1	Supressão	Não mudança	Não mudança	73,38	52,22	-1
2	Regeneração	Não mudança	Não mudança	27,20	19,36	1
3	Não mudança	Supressão	Não mudança	19,47	13,86	-1
4	Regeneração	Supressão	Não mudança	5,93	4,22	0
5	Não mudança	Regeneração	Não mudança	5,21	3,70	1
6	Não mudança	Não mudança	Regeneração	4,51	3,21	1
7	Supressão	Regeneração	Não mudança	2,57	1,83	0
8	Não mudança	Supressão	Regeneração	0,71	0,51	0
9	Supressão	Supressão	Não mudança	0,55	0,39	-2
10	Supressão	Não mudança	Regeneração	0,30	0,22	0
11	Não mudança	Regeneração	Supressão	0,20	0,14	0
12	Regeneração	Supressão	Regeneração	0,15	0,11	1
13	Não mudança	Não mudança	Supressão	0,14	0,10	-1
14	Supressão	Não mudança	Supressão	0,07	0,05	-2
15	Supressão	Regeneração	Supressão	0,05	0,04	-1
16	Regeneração	Não mudança	Regeneração	0,04	0,02	2
17	Regeneração	Regeneração	Não mudança	0,03	0,02	2
18	Não mudança	Regeneração	Regeneração	0,02	0,01	2
19	Não mudança	Não mudança	Não mudança	89,64	NA	0

Ao observar os percentuais de cada trajetória, percebe-se que as 7 primeiras concentram aproximadamente 98% de todas as mudanças que ocorreram durante a série histórica, e 3 delas respondem por 85%. Percebe-se que há uma clara predominância de supressão florestal, principalmente no primeiro período, onde a trajetória 1, que representa coberturas florestais que foram suprimidas entre 1984 e 1994 e não se alteraram posteriormente, corresponde a 52% das mudanças. Com relação as áreas de regeneração florestal, elas também se concentram no primeiro período com quase 20% das mudanças totais seguindo em 3% nos períodos seguintes, mas com um valor quantitativo inferior à supressão. Isto se confirma ao compararmos os percentuais totais das trajetórias que apresentaram índices positivos e negativos, com 67% de trajetórias negativas e 26% de positivas como pode ser observado na Figura 4.5.

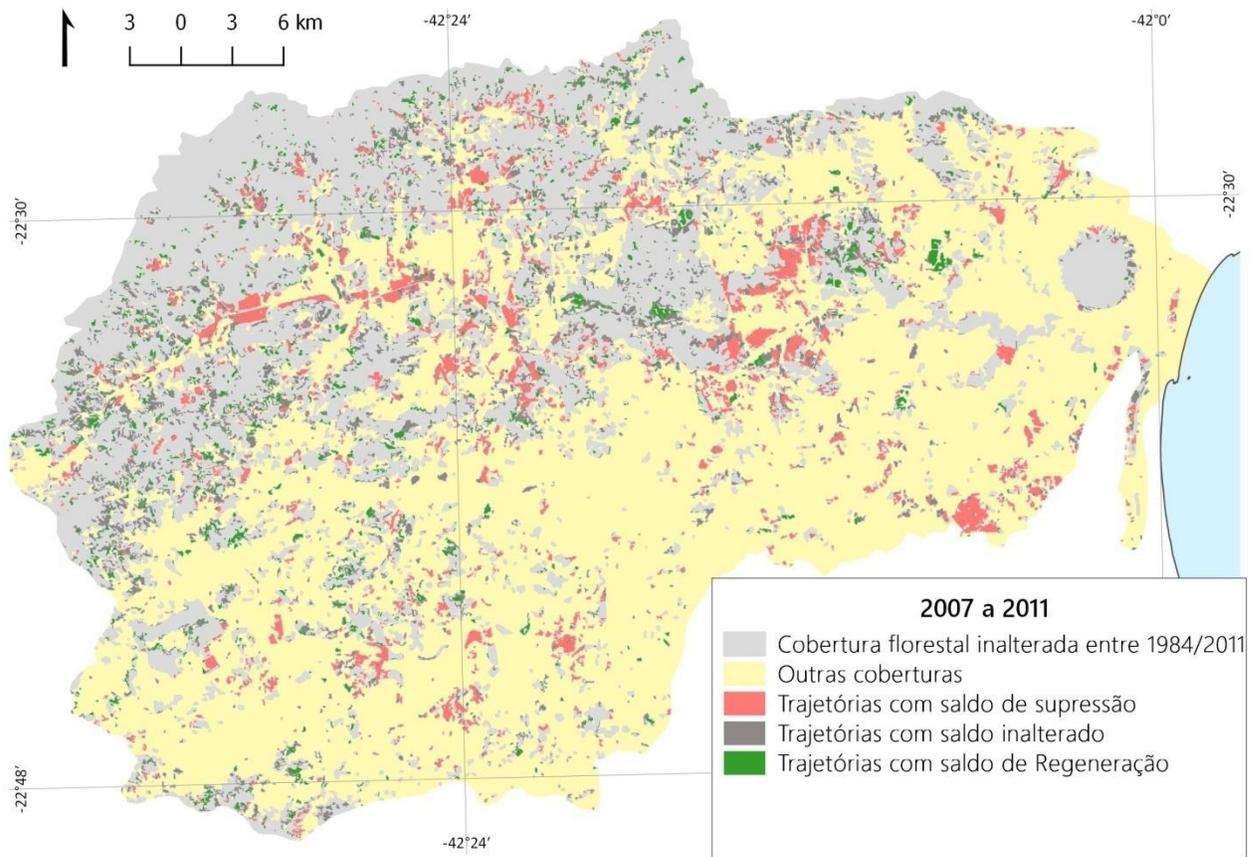


Figura 4.5- Mapa das trajetórias de mudanças de acordo com o saldo final

Uma outra forma de representação e simplificação das trajetórias para uma melhor visualização foi a categorização dos objetos de acordo com o aspecto temporal da supressão ou regeneração, indicando há quanto tempo determinado objeto foi modificado. Dessa forma, foi possível identificar 6 classes possíveis, 3 de supressão e 3 de regeneração, como pode ser analisado na Tabela 12. Vale lembrar que a categoria Suprimido entre 2007 e 2011 foi desconsiderada em função do processo de validação.

Tabela 12- Categorização dos objetos segundo critério de mudança temporal

Trajatória	1984-1994	1994-2007	2007-2011	Categoria temporal
1	Supressão	Não mudança	Não mudança	Suprimido entre 84 e 94
2	Regeneração	Não mudança	Não mudança	Regenerado entre 84 e 94
3	Não mudança	Supressão	Não mudança	Suprimido entre 94 e 07
4	Regeneração	Supressão	Não mudança	Suprimido entre 94 e 07
5	Não mudança	Regeneração	Não mudança	Regenerado entre 94 e 07
6	Não mudança	Não mudança	Regeneração	Regenerado entre 07 e 11
7	Supressão	Regeneração	Não mudança	Regenerado entre 94 e 07
8	Não mudança	Supressão	Regeneração	Regenerado entre 07 e 11
9	Supressão	Supressão	Não mudança	Suprimido entre 84 e 94
10	Supressão	Não mudança	Regeneração	Regenerado entre 07 e 11
11	Não mudança	Regeneração	Supressão	Suprimido entre 07 e 11
12	Regeneração	Supressão	Regeneração	Regenerado entre 07 e 11
13	Não mudança	Não mudança	Supressão	Suprimido entre 07 e 11
14	Supressão	Não mudança	Supressão	Suprimido entre 07 e 11
15	Supressão	Regeneração	Supressão	Suprimido entre 07 e 11
16	Regeneração	Não mudança	Regeneração	Regenerado entre 07 e 11
17	Regeneração	Regeneração	Não mudança	Regenerado entre 94 e 07
18	Não mudança	Regeneração	Regeneração	Regenerado entre 07 e 11

Foi elaborado um mapa (Figura 4.6) com a distribuição espacial dessas categorias. Fica nítido a predominância das classes de supressão entre 1984 e 1994 com grandes objetos localizados, principalmente, nas áreas de baixa declividade. As classes de regeneração se apresentaram de forma mais pulverizada em áreas menores, com exceção das que ocorreram entre 2007 e 2011 onde é possível notar objetos um pouco maiores impulsionados pela plantação de eucaliptos.

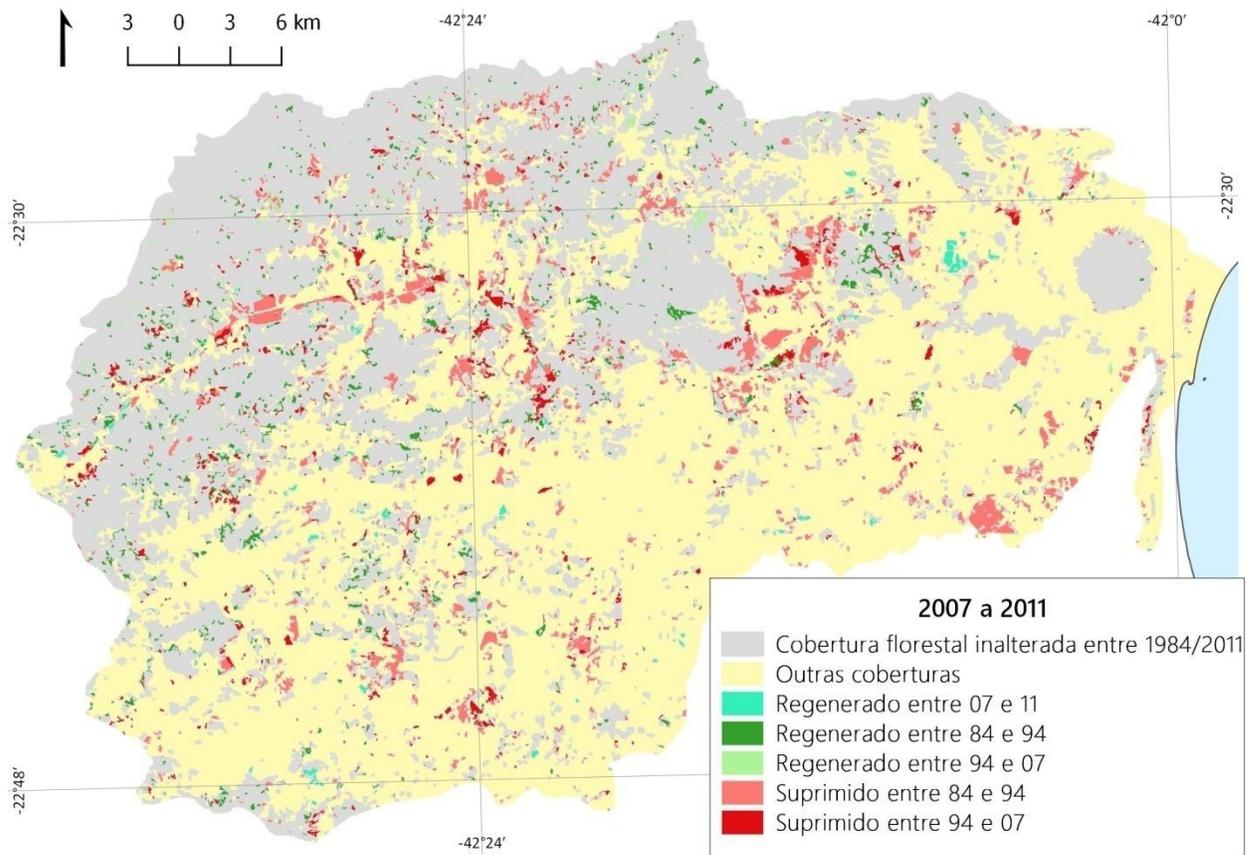


Figura 4.6- Mapa com os tipos de mudanças na cobertura florestal ao longo do tempo

4.3.2.2. Critério detalhado

Este critério considerou todas as classes para fazer as combinações e determinar as trajetórias. Das 125 trajetórias possíveis, 5 classes em 3 períodos, foram detectadas 74 trajetórias. Os mesmos processos de categorização do critério anterior foram aplicados neste enfoque. Assim como no critério simplificado, muitas dessas trajetórias tiveram uma representatividade muito baixa, onde 98% das mudanças se concentraram em 35 trajetórias, conforme pode ser observado na Tabela 13. A tabela original contendo todas as 74 trajetórias pode ser encontrada nos anexos.

Tabela 13- Trajetórias considerando mudanças não florestais

Trajetórias	1984-1994	1994-2007	2007-2011	km ²	%(mudanças)
1	Supressão	Não mudança	Não mudança	44,95	26,68
2	Regeneração	Não mudança	Não mudança	26,87	15,95
3	Regeneração N.F.	Não mudança	Não mudança	15,70	9,32
4	Não mudança	Supressão	Não mudança	14,89	8,84
5	Supressão	Supressão N.F.	Não mudança	9,56	5,67
6	Supressão	Regeneração N.F.	Não mudança	7,09	4,21
7	Supressão	Supressão N.F.	Regeneração N.F.	5,48	3,26
8	Não mudança	Supressão N.F.	Não mudança	4,80	2,85
9	Regeneração	Supressão	Não mudança	4,54	2,70
10	Não mudança	Supressão	Regeneração N.F.	4,05	2,41
11	Não mudança	Regeneração	Não mudança	2,87	1,70
12	Supressão	Regeneração	Não mudança	2,53	1,50
13	Supressão	Não mudança	Supressão N.F.	2,37	1,41
14	Supressão	Não mudança	Regeneração N.F.	2,03	1,21
15	Não mudança	Supressão N.F.	Regeneração N.F.	1,87	1,11
16	Não mudança	Não mudança	Regeneração	1,65	0,98
17	Supressão N.F.	Regeneração	Não mudança	1,45	0,86
18	Supressão	Regeneração N.F.	Supressão N.F.	1,40	0,83
19	Não mudança	Regeneração N.F.	Não mudança	1,33	0,79
20	Regeneração	Supressão	Regeneração N.F.	1,11	0,66
21	Supressão N.F.	Regeneração N.F.	Não mudança	1,09	0,65
22	Supressão N.F.	Não mudança	Não mudança	0,94	0,56
23	Supressão N.F.	Não mudança	Regeneração	0,86	0,51
24	Não mudança	Supressão	Regeneração	0,71	0,42
25	Regeneração N.F.	Regeneração	Não mudança	0,66	0,39
26	Não mudança	Não mudança	Supressão N.F.	0,55	0,33
27	Supressão N.F.	Regeneração N.F.	Regeneração	0,53	0,32
28	Não mudança	Supressão	Supressão N.F.	0,52	0,31
29	Regeneração N.F.	Não mudança	Regeneração	0,48	0,29
30	Não mudança	Supressão N.F.	Regeneração	0,45	0,26
31	Não mudança	Não mudança	Regeneração N.F.	0,39	0,23
32	Regeneração N.F.	Regeneração N.F.	Não mudança	0,36	0,21
33	Supressão	Supressão	Não mudança	0,34	0,20
34	Regeneração	Não mudança	Supressão N.F.	0,33	0,19
35	Supressão	Regeneração N.F.	Regeneração N.F.	0,32	0,19
74	Não mudança	Não mudança	Não mudança	61,71	NA

As mudanças não florestais foram destacadas em amarelo para fins de comparação com a tabela anterior. As cores nas células das porcentagens são para indicar o saldo da trajetória, onde os tons de verde representam a regeneração, os tons de vermelho a supressão e o cinza a regeneração e supressão se compensaram.

Comparado ao critério simplificado, percebe-se uma diminuição do total de áreas que não apresentaram nenhuma mudança ao longo da série histórica, neste caso categorizada como trajetória 74. Ela apresentou uma área de aproximadamente 62 km², uma diminuição de quase 28 km². Isto porque as mudanças não florestais foram contabilizadas como mudanças, que são distribuídas nas novas categorias de trajetórias desse critério. Por um lado, o aumento no número dos tipos de trajetórias pode dificultar a análise e criar alguns tipos de trajetórias improváveis, por outro, pode ajudar a diferenciar as trajetórias do critério simplificado indicando mais detalhes sobre a dinâmica das mudanças. Por exemplo, se compararmos a trajetória de maior ocorrência nos dois critérios, que foi a supressão no primeiro período e não mudança nos períodos seguintes, há uma diferença de 28 km², que foram distribuídas entre as trajetórias 5; 6 ;7; 13; 14; 18 e 35. Esses 28 km², indicam áreas que foram suprimidas entre 1984 e 1984, e que continuaram tendo algum tipo de atividade nos períodos seguintes, provavelmente convertidas em áreas agrícolas. Enquanto os 45 km² da trajetória 1 do critério detalhado provavelmente foi convertido em áreas de pastagens ou em alguma outra atividade que não resulta em modificações perceptíveis nessa metodologia. Neste estudo, essa trajetória foi a que apresentou maior diferença de valor com a alteração dos critérios, principalmente por concentrar a maior parte das mudanças, mas as outras trajetórias também foram em menor grau. Percebeu-se que as maiores diferenças foram encontradas nas trajetórias que prevaleceram a supressão.

5. Considerações finais

5.1. Quanto ao método

De uma maneira geral, a metodologia proposta apresentou resultados satisfatórios, com uma boa porcentagem de acertos (*Kappa* 0,9 para classificação multitemporal e 0,8 para as bitemporais), e a capacidade de identificar mudanças de diferentes intensidades distinguindo-as entre mudanças florestais e não florestais. A implementação através da árvore de processo e a flexibilidade da escolha de limiares permitem uma fácil replicação do método. Como as análises em GEOBIA demandam uma capacidade de processamento alto, o uso de apenas duas variáveis por data otimiza esses custos, o que viabiliza a utilização de séries temporais com maior quantidade de imagens. O produto final em formato vetorial com a combinação de informações de todos os períodos amplia a possibilidade de análises espaciais independentes do software eCognition a partir da integração com outros tipos de informações. Apesar da resolução espacial adotada neste método não diferenciar espectralmente a cobertura florestal natural da silvicultura, através de um recorte temporal maior, com intervalos de tempo menores, seria possível caracteriza-la de acordo com o padrão de plantio e supressão observados através da série.

Para atingir melhores resultados, o método, como de praxe, se mostra dependente de imagens pré-processadas, já ajustadas geometricamente e normalizadas. Uma limitação relevante foi a adoção de um software comercial de alto custo, embora esteja crescendo o número de iniciativas de solução similar em outros sistemas. A estruturação do modelo adotado de forma conceitual nesta tese possibilita não só a sua compreensão lógica como a transferência para outros sistemas comerciais ou customizáveis (desenvolvimento em alguma linguagem de programação), em abordagem baseada em *pixel* ou objetos.

5.2. Quanto aos resultados

A dinâmica da cobertura florestal na área apresentou diminuição ao longo da série, com estabilização nos últimos anos. Isto pode ser justificado por medidas conservacionistas adotadas no início dos anos 2000 como a criação da APA do rio São João e a definição das Áreas de Proteção Permanente (APP). Soma-se a isso a estagnação econômica da região, que diminuiu a pressão sobre os recursos naturais, com exceção para a atividade de silvicultura, que vem ganhado força na região, conforme o detectado no último período analisado. Observa-se uma diminuição das áreas

de supressão e regeneração ao longo dos períodos, com a supressão chegando a, praticamente, zero e a regeneração à quase 6 Km² (em função da silvicultura). As mudanças mais significativas ocorreram no primeiro período, entre 1984 e 1994, o que sugere uma análise mais detalhada desse período. Seria interessante aplicar o modelo somente nesse período, subdividindo-o em intervalos menores para detalhar a dinâmica dessas mudanças. Como as mudanças mais recentes são mais sutis, essa escala de análise não é suficiente para detectá-las, se fazendo necessário imagens com maior resolução espacial.

Outro aspecto importante a ressaltar é a classificação das não mudanças nas etapas multitemporal e bitemporal. Na análise multitemporal separou-se as áreas de não mudança em cobertura florestal das mudanças em cobertura florestal, porém, mesmo como uma alta exatidão global (95%), algumas áreas de mudança foram classificadas como não mudança. Optou-se por escolher um modelo mais flexível para área de não mudança para evitar erros de comissão (áreas de mudança sendo classificadas como não mudança), e garantir que, praticamente, todas as áreas de mudanças fossem incluídas. Os erros de omissão (áreas classificadas como mudança, mas que eram não mudanças) poderiam a ser identificados nas trajetórias dos objetos após as classificações bitemporais. Essas áreas representaram 61 Km² (Tabela 13), aproximadamente 25% das áreas de mudanças, e apesar de parecer um percentual alto, há de se considerar que ela é referente somente as áreas de mudanças. Se compararmos com a área total de possíveis coberturas florestais esse percentual diminui para 5%, e se mantém alinhado como a exatidão global da classificação multitemporal.

5.3. Perspectivas futuras

Para uma consolidação dessa metodologia é necessário replicá-la em outras áreas da mata atlântica que apresentem dinâmicas diferentes para entender sua resposta em outros contextos e o quanto os modelos e limiares adotados se mantêm. Outra aplicação interessante é o estudo de sua adaptação em áreas de floresta manejada, onde se tem um maior controle sobre as mudanças, facilitando o processo de validação. Como a mata atlântica já é um bioma altamente fragmentado, não encontramos grandes áreas de supressão e as áreas de regeneração são ainda mais sutis, sendo perceptíveis apenas numa análise em uma escala de tempo mais longa ou em resoluções espaciais maiores. Desta forma, a análise em florestas manejadas proporciona uma oportunidade de

observação de mudanças constantes, e que as vezes nos ajudam a identificar padrões que possam qualificar o tipo de manejo.

Para que esta proposta seja utilizada em estudos de detecção de mudanças que cubram período atuais, se faz necessária a realização de testes para observar a adequação do modelo com imagens do sensor OLI, a bordo do Landsat 8, e dos sensores do Sentinel 2, pois essas são as principais fontes de imagens de média resolução gratuitas que estão em atividade atualmente. Uma outra frente de continuidade seria utilizar imagens de alta resolução para avaliar como o modelo se comportaria, observando-se que o fato do principal descritor ter sido a banda do SWIR limita bastante a seleção de opções. Com o acesso cada vez mais fácil a esse tipo de produto, como VANT e a disseminação de microssatélites, e o GEOBIA ser adequado para esse tipo de dado, essa pode ser uma tendência interessante. O aumento da resolução temporal também pode ser explorado conforme a capacidade de processamento dos *hardwares* melhorar.

Também é possível explorar as análises baseadas em *pixel* num contexto multitemporal usando uma série histórica mais completa. Atualmente surgem opções gratuitas de sistemas baseados em *bigdata* que apresentam bibliotecas de funções que podem ser programadas e processadas na nuvem, como o *Google Earth Engine*. Por fim, tem-se estudado ainda a possibilidade de integração de diferentes abordagens, num contexto denominado híbrido, buscando-se vantagens em cada processo para soluções de maior complexidade.

6. Referências

AL KHUDHAIRY, D. H. A.; CARAVAGGI, I.; GLADA, S. Structural damage assessments from Ikonos data using change detection, object-oriented segmentation, and classification techniques. **Photogrammetric Engineering & Remote Sensing**, **71**, 2005. 825-837.

ALBUQUERQUE, C. K. Avaliação Qualitativa de Fragmentos Florestais com Dados de Sensoriamento Remoto como subsídio à formação de Corredores Ecológicos na APA São João. **Dissertação de Mestrado. PPGG, UFRJ**, Rio de Janeiro, 2010.

ALONSO, W. **Location and Land Use: Towards a General Theory of Land Rent**. Cambridge: Harvard University Press, 1964.

AN, K.; ZHANG, J.; XIAO, Y. Object-oriented urban dynamic monitoring – a case study of Haidian District of Beijing. **Chinese Geographical Science**, 2007. 236-242.

ANDERSON, J. R. et al. A Land Use and Land Cover Classification System for Use with Remote Sensor Data. **U.S. Geological Survey Professional Paper**, 1976. 28.

BLASCHKE, T. Contextual approaches using image segmentation for object-based classification. In: DE MEER, F.; DE JONG, S. **Remote Sensing Image Analysis: Including the spatial domain**. Dordrecht: Kluwer Academic Publishers, 2004. p. 221-236.

BLASCHKE, T. Towards a framework for change detection based on image objects. **Göttinger Geographische Abhandlungen**, 2005. 1-9.

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**, 2008. 3181-3191.

BRIASSOULIS, H. **Analysis of Land Use Change: Theoretical and Modeling Approaches**. West Virginia: West Virginia University, 2000.

CAMARA, G. et al. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computer & Graphics**, 1996. 395-403.

CARVALHO, L. M. T. et al. Wavechange: a procedure for change detection based on wavelet product spaces. **Proceedings of the International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp 2007)**, Leuven, 2007. 5.

CHEN, G.; HAY, G. J. An airborne lidar sampling strategy to model forest canopy height from Quickbird imagery and GEOBIA. **Remote Sensing of Environment**, v. 115, n. 6, p. 1532–1542, Junho 2011.

CHRISTALLER, W. **Central Places in Southern Germany** (translated by C.W. Baskin). Englewood Cliffs: Prentice-Hall , 1966.

DE CHANT, T.; KELLY, M. Individual object change detection for monitoring the impact of a forest pathogen on a Hardwood forest. **Photogrammetric Engineering & Remote Sensing**, 2009. 1005-1013.

DESCLÉE, B.; BOGAERT, P.; DEUFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, 2006. 1-11.

DI GREGORIO, A.; JANSEN, L. J. M. Land cover Classification System(LCCS): Classification concepts and user manual. **Environment and Natural Resources Service (SDRN), FAO**, Roma, 2000.

FERNANDES, P. J. F.; VICENS, R. S.; FURTADO, L. F. A. Modelo automático de normalização radiométrica de série multitemporal Landsat-5 usando pontos pseudoinvariantes(PIF). **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 69, p. 241-251, 2017. ISSN 1808-0936.

FISHER, P. F.; COMBER, A. J.; WADSWORTH, R. Land use and Land cover: Contradiction or Complement. In: FISHER, P. F.; UNWIN, D. **Re-Presenting GIS**. [S.l.]: John Wiley Professional, 2005. p. 296.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, 2002. 185-201.

GONÇALVES, H. S.. Correlações Espaciais entre Mudanças nas Formas/Funções da Paisagem Rural e a socioeconomia de Entorno: um input a temas de planejamento na Bacia do Rio

São João RJ usando Geotecnologias. **Dissertação de Mestrado. PPGG, UFRJ**, Rio de Janeiro, 2012.

GONG, J. et al. Object-level change detection based on full-scale image segmentation and its application to Wenchuan Earthquake. **Science in China Series E: Technological Sciences**, 2008. 110-122.

HALL, F. G. et al. Radiometric rectification: toward a common radiometric response among multitemporal, multisensory images. **Remote Sensing of Environment**, v. 35, p. 11-27, 1991. ISSN 1.

HALL, O.; HAY, G. J. A multiscale object-specific approach to digital change detection. **International Journal of Applied Earth Observation and Geoinformation**, 2003. 311-327.

HANSEN, M. C. et al. Humid tropical forest disturbance alerts using Landsat data. **Environmental Research Letters**, 11, 2016.

HAY, G. J.; CASTILLA, G. Geographic object-based image analysis (GEOBIA). In: BLASCHKE, T.; LANG, S.; HAY, G. J. **Object-Based Image Analysis – Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Berlin: Springer, 2008. p. 77-92.

HAY, G. J.; NIEMANN, K. O.; GOODENOUGH, D. G. Spatial thresholds, image-objects and upscaling: a multiscale evaluation. **Remote Sensing of Environment**, 1997. 1-19.

IBGE. **Manual técnico de uso da terra 3ª edição**. Instituto Brasileiro de Geografia e Estatística. Rio de Janeiro. 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**, 29, 2008. 399-423.

LALIBERTE, A. D. et al. Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico. **Remote Sensing of Environment**, 2004. 198-210.

LI, C. et al. Comparison of classification algorithms and training sample sizes in urban land classification with Landsat Thematic Mapper imagery. **Remote Sensing**, 2014. 964-983.

LIVERMAN, D. et al. **People and Pixels: Linking Remote Sensing and Social Science**. Washington D.C.: National Academy Press, 1998.

LU, D. et al. Change detection techniques. **International Journal of Remote Sensing**, **25**, 2004. 2365-2407.

LUCC. **Land Use and Land Cover: Implementation Strategy**. IGBP. Stockholm. 1999. (IGBP Report 48).

MACQUEEN, J. B. **Some methods for classification and analysis of multivariate observations**. Proceedings of 5th Berkeley Symposium on mathematical statistics and probability. Berkeley, p. 281-297. 1967.

MARSH, G. P. **Man and Nature**. Cambridge: Press of Harvard University Press, 1965.

MCDERMID, G. J. et al. Object-based approaches to change analysis and thematic map update: challenges and limitation. **Canadian Journal of Remote Sensing**, 2008. 462-466.

MEYER, W. B.; TURNER, B. L. Land-Use/Land-Cover Change: Challenges for Geographers. **Geojournal**, 1996. 237-240.

MILLER, O.; PIKAZ, A.; AVERBUCH, A. Objects based change detection in a pair of gray-level images. **Pattern Recognition**, 2005. 1976-1992.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man and Cybernetics**, 1979. 62-66.

OWOJORI, A.; XIE, H. Landsat image-based LULC changes of San Antonio, Texas using advanced atmospheric correction and object-oriented image analysis approaches. **Proceedings of the 5th International Symposium on Remote Sensing of Urban Areas**, Tempe, 2005.

PONZONI, F. V.; SHIMABUKURU, Y. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Parêntese, 2009.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical**, Vienna, 2018. <https://www.R-project.org/>.

REIS, R. B. Mapeamento das áreas de preservação permanente (APP) como subsídio à elaboração de estratégias de conservação e recuperação estudo de caso na APA do Rio São João / Mico Leão Dourado. **Dissertação de Mestrado. PPGG, UFRJ, 2008.**

ROGAN, J.; FRANKLIN, J.; ROBERTS, D. A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, 2002. 143-156.

ROUSE, J. W. et al. **Monitoring Vegetation Systems in the Great Plains with ERTS.** hird Earth Resources Technology Satellite-1 Symposium. Geenbelt: NASA. 1974. p. 309.

SEABRA, V. S. Análise da Paisagem em apoio aos estudos de Favorabilidade à Recuperação Florestal na bacia hidrográfica do rio São João. **Tese de Doutorado. PPGG, UFRJ, Rio de Janeiro, 2012.**

SINGH, A. Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, **10**, 1989. 898–1003.

SONG, C. et al. Classification and change detection using Landsat TM data: When and how to correct atmospheric effects?. **Remote Sensing of Environment**, **75**, 2001. 230-244.

STOW, D. et al. Monitoring shrubland habitat changes through object-based change identification with airborne multispectral imagery. **Remote Sensing of Environment**, 2008. 1051-1061.

TRIMBLE. **Ecognition Reference Book.** Munich: [s.n.], 2014.

TURNER, B. L. et al. Land-use and land-cover change. **IGBP report. 5**, 1994.

USGS. **https://landsat.usgs.gov/geometry.** Disponível em: <<https://landsat.usgs.gov/geometry>>. Acesso em: 2017.

VON THUNEN, J. H. **Isolated State, an English translation of "Der Isolierte Staat" by C.M. Wartenberg.** [S.l.]: Oxford: Pergamon Press, 1966.

WALTER, W. Object-based classification of remote sensing data for change detection, 2004. 225-238.

WU, X.; YANG, F.; LISHMAN, R. Land cover change detection using texture analysis. **Journal of Computer Science**, 2010. 92-100.

YU, X. et al. Automatic detection of harvested trees and determination of forest growth using airborne laser scanning. **Remote Sensing of Environment**, 2004. 451-462.

ZHOU, W.; TROY, A.; GROVE, M. Object-based land cover classification and change analysis in the Baltimore metropolitan area using multitemporal high resolution remote sensing data. **Sensor**, 2008. 1613-1636.

7. Anexos

Gráficos de Normalização

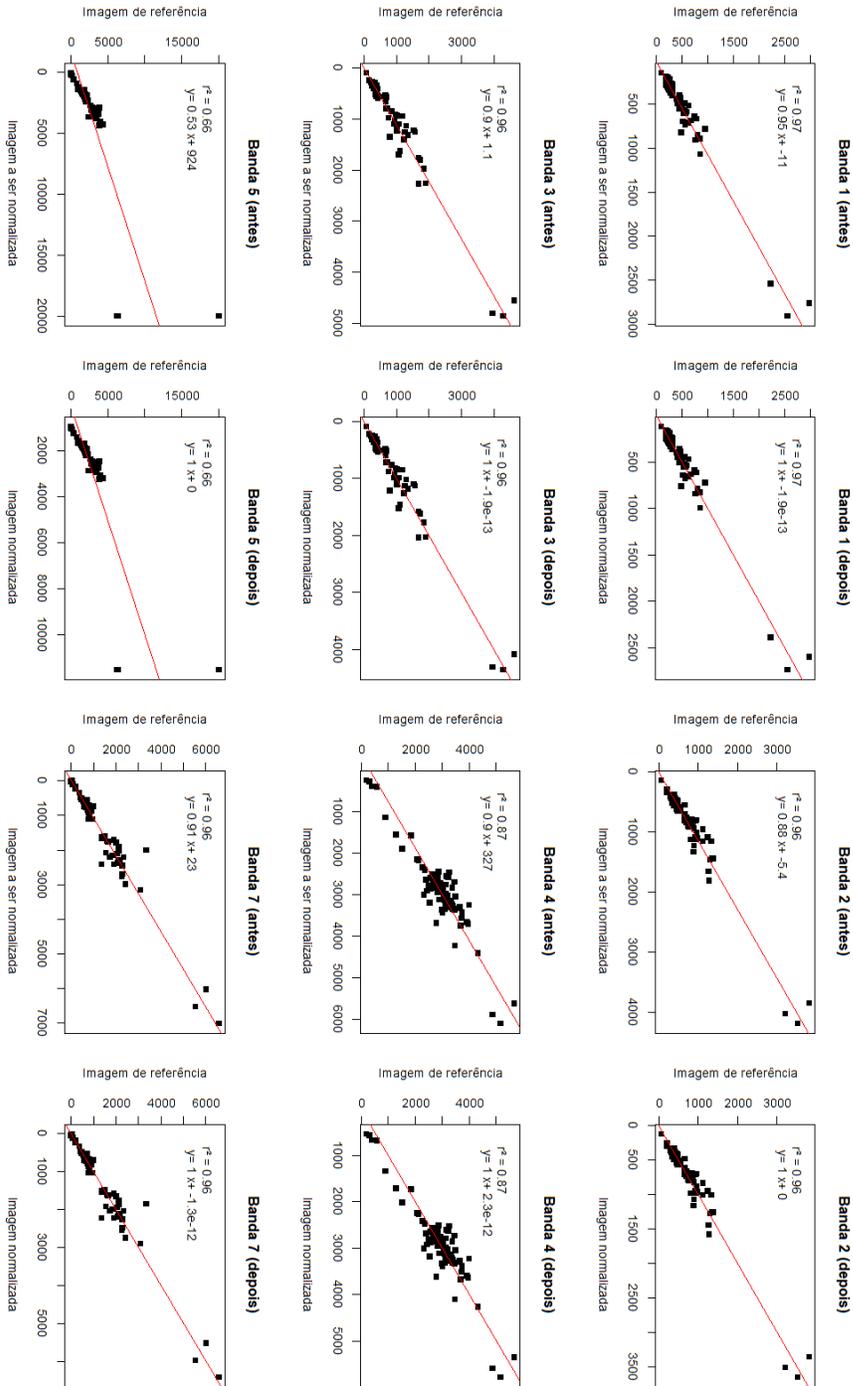


Gráfico 7.1- Gráficos normalização 1984

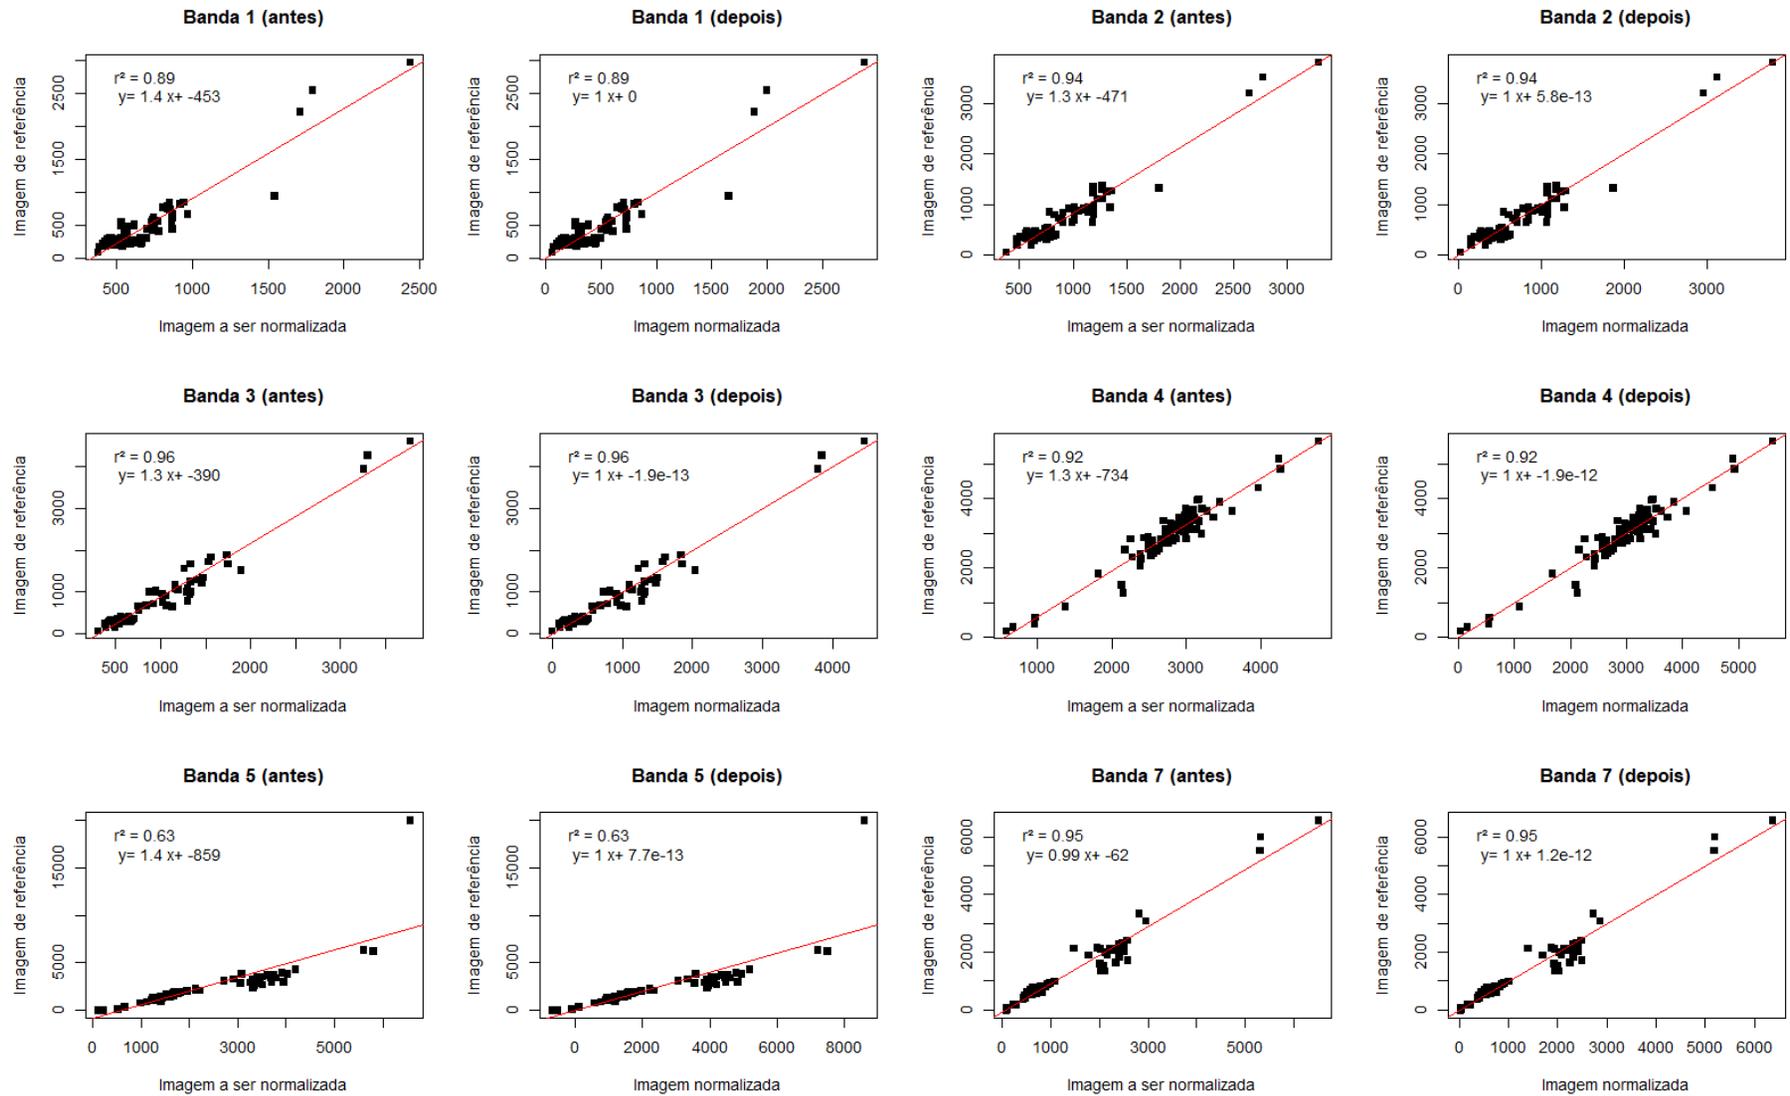


Gráfico 7.2- Gráficos normalização 2007

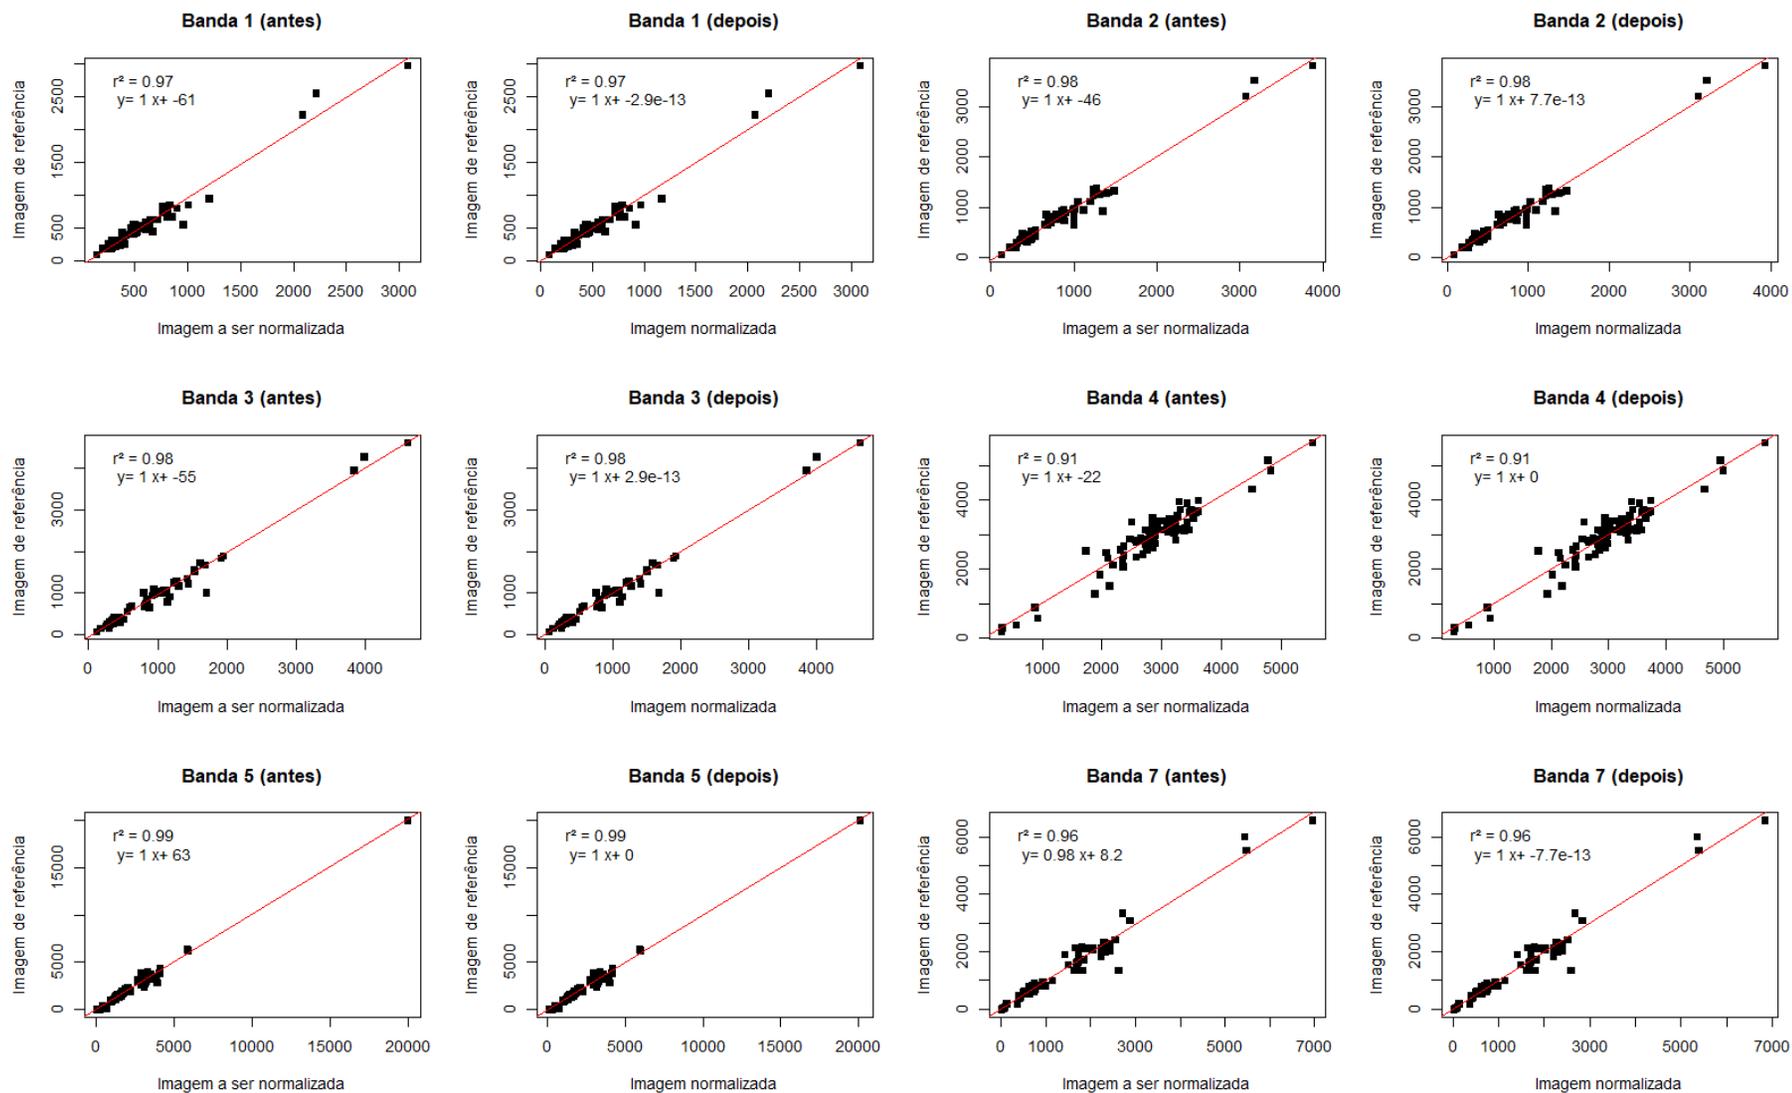


Gráfico 7.3- Gráficos normalização 2011

Tabela da Trajetória detalhada

Tabela 14- Tabela da trajetória detalhada

Trajetórias	1984-1994	1994-2007	2007-2011	Km ²	%(mudanças)
1	Supressão	Não mudança	Não mudança	44,95	26,68
2	Regeneração	Não mudança	Não mudança	26,87	15,95
3	Regeneração N.F.	Não mudança	Não mudança	15,70	9,32
4	Não mudança	Supressão	Não mudança	14,89	8,84
5	Supressão	Supressão N.F.	Não mudança	9,56	5,67
6	Supressão	Regeneração N.F.	Não mudança	7,09	4,21
7	Supressão	Supressão N.F.	Regeneração N.F.	5,48	3,26
8	Não mudança	Supressão N.F.	Não mudança	4,80	2,85
9	Regeneração	Supressão	Não mudança	4,54	2,70
10	Não mudança	Supressão	Regeneração N.F.	4,05	2,41
11	Não mudança	Regeneração	Não mudança	2,87	1,70
12	Supressão	Regeneração	Não mudança	2,53	1,50
13	Supressão	Não mudança	Supressão N.F.	2,37	1,41
14	Supressão	Não mudança	Regeneração N.F.	2,03	1,21
15	Não mudança	Supressão N.F.	Regeneração N.F.	1,87	1,11
16	Não mudança	Não mudança	Regeneração	1,65	0,98
17	Supressão N.F.	Regeneração	Não mudança	1,45	0,86
18	Supressão	Regeneração N.F.	Supressão N.F.	1,40	0,83
19	Não mudança	Regeneração N.F.	Não mudança	1,33	0,79
20	Regeneração	Supressão	Regeneração N.F.	1,11	0,66
21	Supressão N.F.	Regeneração N.F.	Não mudança	1,09	0,65
22	Supressão N.F.	Não mudança	Não mudança	0,94	0,56
23	Supressão N.F.	Não mudança	Regeneração	0,86	0,51
24	Não mudança	Supressão	Regeneração	0,71	0,42
25	Regeneração N.F.	Regeneração	Não mudança	0,66	0,39
26	Não mudança	Não mudança	Supressão N.F.	0,55	0,33
27	Supressão N.F.	Regeneração N.F.	Regeneração	0,53	0,32
28	Não mudança	Supressão	Supressão N.F.	0,52	0,31
29	Regeneração N.F.	Não mudança	Regeneração	0,48	0,29
30	Não mudança	Supressão N.F.	Regeneração	0,45	0,26
31	Não mudança	Não mudança	Regeneração N.F.	0,39	0,23
32	Regeneração N.F.	Regeneração N.F.	Não mudança	0,36	0,21
33	Supressão	Supressão	Não mudança	0,34	0,20
34	Regeneração	Não mudança	Supressão N.F.	0,33	0,19
35	Supressão	Regeneração N.F.	Regeneração N.F.	0,32	0,19
36	Não mudança	Supressão N.F.	Supressão N.F.	0,32	0,19
37	Regeneração	Supressão	Supressão N.F.	0,27	0,16
38	Não mudança	Regeneração N.F.	Regeneração	0,26	0,16
39	Supressão	Não mudança	Regeneração	0,25	0,15

40	Regeneração N.F.	Supressão N.F.	Regeneração	0,19	0,11
41	Supressão	Supressão	Regeneração N.F.	0,19	0,11
42	Supressão	Supressão N.F.	Supressão N.F.	0,18	0,11
43	Supressão N.F.	Regeneração	Supressão N.F.	0,17	0,10
44	Regeneração	Supressão	Regeneração	0,15	0,09
45	Regeneração N.F.	Supressão N.F.	Regeneração N.F.	0,14	0,08
46	Não mudança	Regeneração	Supressão	0,14	0,08
47	Não mudança	Não mudança	Supressão	0,12	0,07
48	Regeneração N.F.	Supressão N.F.	Não mudança	0,10	0,06
49	Supressão N.F.	Não mudança	Regeneração N.F.	0,09	0,05
50	Supressão	Não mudança	Supressão	0,07	0,04
51	Regeneração N.F.	Não mudança	Regeneração N.F.	0,07	0,04
52	Supressão N.F.	Regeneração N.F.	Regeneração N.F.	0,06	0,04
53	Supressão	Regeneração	Supressão	0,05	0,03
54	Supressão N.F.	Supressão N.F.	Regeneração	0,05	0,03
55	Regeneração N.F.	Não mudança	Supressão N.F.	0,05	0,03
56	Supressão N.F.	Regeneração	Supressão	0,05	0,03
57	Supressão	Regeneração N.F.	Regeneração	0,04	0,02
58	Não mudança	Regeneração	Supressão N.F.	0,04	0,02
59	Regeneração	Não mudança	Regeneração	0,04	0,02
60	Supressão	Regeneração	Supressão N.F.	0,03	0,02
61	Regeneração	Regeneração	Não mudança	0,03	0,02
62	Regeneração N.F.	Regeneração N.F.	Regeneração	0,03	0,02
63	Regeneração N.F.	Não mudança	Supressão	0,03	0,02
64	Supressão N.F.	Supressão N.F.	Regeneração N.F.	0,03	0,01
65	Regeneração N.F.	Regeneração	Supressão N.F.	0,02	0,01
66	Supressão N.F.	Regeneração	Regeneração	0,02	0,01
67	Supressão	Supressão	Supressão N.F.	0,02	0,01
68	Regeneração N.F.	Regeneração N.F.	Supressão N.F.	0,02	0,01
69	Regeneração N.F.	Regeneração	Supressão	0,01	0,01
70	Regeneração N.F.	Regeneração N.F.	Regeneração N.F.	0,01	0,01
71	Supressão	Supressão N.F.	Regeneração	0,01	0,01
72	Regeneração N.F.	Supressão	Não mudança	0,01	0,01
73	Regeneração N.F.	Supressão N.F.	Supressão N.F.	0,01	0,00
74	Não mudança	Não mudança	Não mudança	61,71	NA

Árvore de Processo

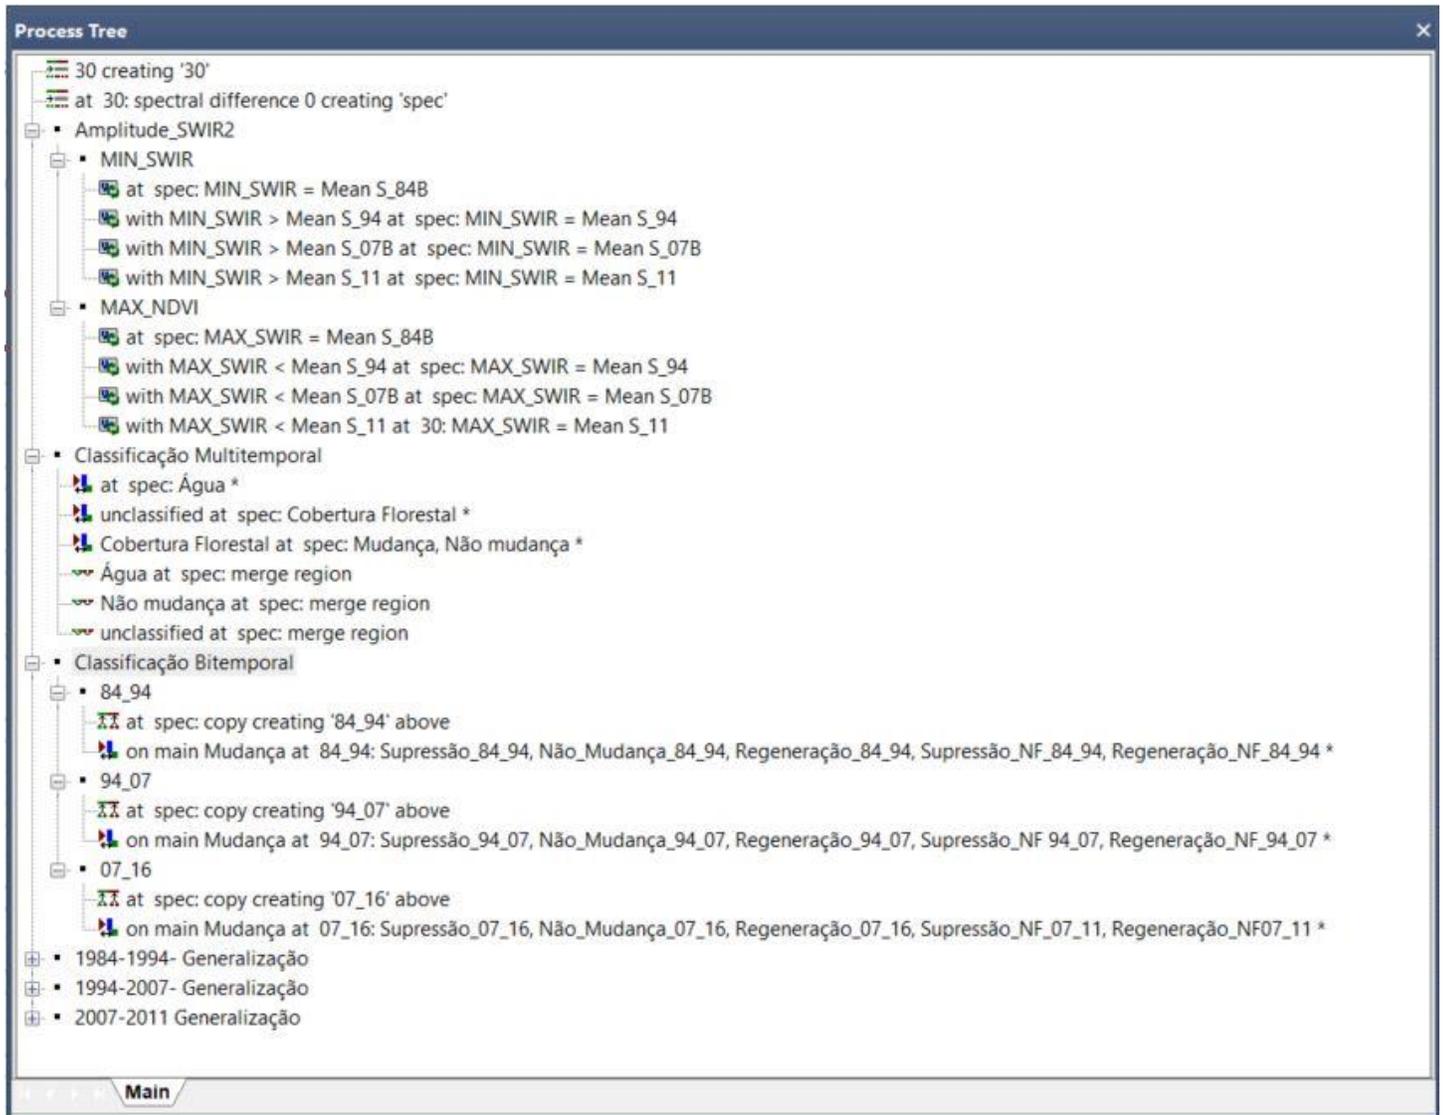


Figura 7.1- Árvore de processo