



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/08.10.11.27-TDI

**ANÁLISE DAS MUDANÇAS DA COBERTURA DA
TERRA CAUSADAS PELO DESASTRE DE
MARIANA-MG UTILIZANDO SÉRIES TEMPORAIS DE
ÍNDICES DE VEGETAÇÃO**

Daiane Vieira Vaz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Leila Maria Garcia
Fonseca e Thales Sehn Körting,
aprovada em 17 de agosto de 2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/43377AL>>

INPE
São José dos Campos
2020

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/08.10.11.27-TDI

**ANÁLISE DAS MUDANÇAS DA COBERTURA DA
TERRA CAUSADAS PELO DESASTRE DE
MARIANA-MG UTILIZANDO SÉRIES TEMPORAIS DE
ÍNDICES DE VEGETAÇÃO**

Daiane Vieira Vaz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Leila Maria Garcia
Fonseca e Thales Sehn Körting,
aprovada em 17 de agosto de 2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/43377AL>>

INPE
São José dos Campos
2020

Dados Internacionais de Catalogação na Publicação (CIP)

Vaz, Daiane Vieira.

V477a Análise das mudanças da cobertura da terra causadas pelo desastre de Mariana-MG utilizando séries temporais de índices de vegetação / Daiane Vieira Vaz. – São José dos Campos : INPE, 2020.

xxii + 94 p. ; (sid.inpe.br/mtc-m21c/2020/08.10.11.27-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.

Orientadores : Drs. Leila Maria Garcia Fonseca e Thales Sehn Körting.

1. Big Data. 2. Random Forest. 3. Sensoriamento remoto. 4. Dados multisensor. 5. Classificação da cobertura da terra. I.Título.

CDU 528.8:332.3(815.1)



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

FOLHA DE APROVAÇÃO

A FOLHA DE APROVAÇÃO SERÁ INCLUIDA APÓS RESTABELECIMENTO DAS ATIVIDADES PRESENCIAIS.

Por conta da Pandemia do COVID-19, as defesas de Teses e Dissertações são realizadas por vídeo conferência, o que vem acarretando um atraso no recebimento nas folhas de aprovação.

Este trabalho foi aprovado pela Banca e possui as declarações dos orientadores (confirmando as inclusões sugeridas pela Banca) e da Biblioteca (confirmando as correções de normalização).

Assim que a Biblioteca receber a Folha de aprovação assinada, esta folha será substituída.

Qualquer dúvida, entrar em contato pelo email: pubtc@inpe.br.

Divisão de Biblioteca (DIBIB).

“Educação é uma descoberta progressiva de nossa própria ignorância”.

Descoberta progressiva

Voltaire

*Ao meu pai Geovane, a minha mãe Neidilane, ao meu
irmão Maycon e ao meu namorado Willian.*

AGRADECIMENTOS

Agradeço a Deus por me abençoar e conceder fé, paciência e sabedoria ao longo destes anos.

A minha mãe Neidilane, pai Geovane, irmão Maycon, ao meu namorado Willian, pelo apoio, incentivo e carinho durante esta etapa.

Aos meus orientadores, Dra. Leila Maria Garcia Fonseca e Dr. Thales Sehn Körting, pela confiança, apoio e ensinamentos.

Ao Instituto Nacional de Pesquisas Espaciais por fornecer toda a estrutura necessária para o desenvolvimento deste trabalho.

Ao pesquisador Dr. Laércio Massaru Namikawa, a Divisão de Processamento de Imagens - DPI/INPE e aos projetos Brazil Data Cube e SOS Mata Atlântica por fornecer os dados necessários ao desenvolvimento do trabalho.

A todos os amigos e colegas, Dayanne, Anderson, Izack, Mikhaela, dentre outros pelo apoio.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, pela concessão da bolsa de estudo.

E todos que de alguma forma contribuíram para minha formação, o meu muito obrigada!

RESUMO

O rompimento da barragem de Fundão, também conhecido como desastre de Mariana, ocorreu em 05 de novembro de 2015. O acidente impactou áreas de vegetação nativa, pastagem, áreas agrícolas e áreas urbanas. Mudanças nas propriedades do solo devido à movimentação de massas e à deposição de rejeitos, associadas a movimentação de bancos de sementes, deixam incertezas quanto capacidade de regeneração da flora afetada pelo desastre. Estas mudanças, associadas à implantação de planos de ação para a recuperação de áreas afetadas, têm modificado a cobertura da terra após o acidente. Neste contexto, o presente trabalho mapeou e analisou mudanças da cobertura da terra ocorridas na área afetada pelo desastre de Mariana, com o diferencial de explorar séries temporais de NDVI. A série temporal foi composta em uma abordagem multisensor, utilizando as coleções de imagens Landsat-7/ETM+, Landsat-8/OLI, CBERS-4/MUX e Sentinel-2/MSI, no período de 2013 a 2019, buscando uma série temporal densa e sem aplicação de processos de harmonização dos dados. As classes de cobertura da terra mapeadas nos cenários pré e pós-desastre foram: afloramento rochoso, mineração, água/rejeito, área construída, gramíneas e herbáceas, formação florestal, formação savânica e agricultura. A classificação foi realizada utilizando o classificador *Random Forest*, e as séries temporais de NDVI, combinadas ou não, com métricas fenológicas. Os produtos de classificação obtidos apresentaram acurácias globais de 81,13% e 85,45% para os cenários pré-desastre e pós-desastre, respectivamente. A utilização das métricas empregadas na classificação, em conjunto com as séries temporais de NDVI, proporcionou ganhos consideráveis na acurácia de pelo menos três classes de interesse. As análises realizadas evidenciaram o impacto causado pelo desastre de Mariana, sendo identificados mais de 300 hectares de áreas degradadas.

Palavras-chave: Big Data. Random Forest. Sensoriamento Remoto. Dados multisensor. Classificação da cobertura da terra.

ANALYSIS OF LAND-COVER CHANGES CAUSED BY THE MARIANA-MG DISASTER USING TIME SERIES OF VEGETATION INDICES

ABSTRACT

The Fundão dam's disruption occurred on November 5th, 2015. The accident affected native vegetation, pasture, agriculture and urban areas. Changes in the soil caused by mass movements and in the soil properties due to the tailings, as well as a possible movimentation of seed bands, bring uncertainties regarding the flora regeneration in the region affected by the disaster. These changes, along with the implementation of recovery plans for the damaged areas, have modified the region's land cover. In this study, we mapped the land cover in the area affected by the Mariana dam disaster, using NDVI time series. In order to build the time series, we adopted a multisensor approach using images acquired from the Landsat-7/ETM+, Landsat-8/OLI, CBERS-4/MUX e Sentinel-2/MSI sensors, regarding the period from 2013 to 2019. The land cover classes mapped include rock formation, mining, water/tailing, constructed area, forest formation, savanna, grassland and agriculture. We performed the land cover classification using Random Forest and the NDVI time series. The classification products presented overall accuracies of 81.13% and 85.45% for the pre- and post-disaster scenarios, respectively. We adopted a set of phenological metrics into the classifications, which increased accuracy in at least three of the considered classes. The analysis performed in this study highlighted the impacts caused by the Mariana dam disaster, since we identified more than 300 hectares of damaged areas.

Keywords: Big data. Random Forest. Remote Sensing. Multisensor data. Land cover classification.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Número de desastres tecnológicos no mundo (2009 – 2019), segundo dados do EM-DAT.....	5
Figura 2.2 – Barragens de responsabilidade da empresa Samarco Mineração S/A. ...	10
Figura 2.3 – Imagens WorldView-2 pré e pós-desastre de Mariana.....	11
Figura 2.4 – Trecho fiscalizado pela Operação Watu.	13
Figura 2.5 – Variação do pixel em uma série temporal de imagens NDVI.....	18
Figura 2.6 – Métricas fenológicas extraídas pelo TIMESAT (espectro esquemático)...	20
Figura 2.7 – Exemplo de árvore de decisão gerada para classificação utilizando dados de NDVI.	22
Figura 2.8 – Funcionamento do método Random Forest.....	23
Figura 3.1 – Mapa de localização da área de estudo.....	28
Figura 3.2 – Fluxograma das etapas da metodologia.....	31
Figura 3.3 – Preenchimento dos dados faltantes.	34
Figura 3.4 – Mapa de localização da área de estudo.....	40
Figura 4.1– Dispersão da série temporal.	43
Figura 4.2 – Classificação das séries temporais de NDVI pré-desastre.....	44
Figura 4.3 – Classificação das séries temporais de NDVI e métricas fenológicas pré-desastre.	44
Figura 4.4 – Comparação das classificações pré-desastre para duas regiões.....	47
Figura 4.5 – Importância de cada atributo utilizado nas classificações pré-desastre. ...	49
Figura 4.6 – Resultado da aplicação de filtro de moda.	50
Figura 4.7 – Imagens de áreas de produção de cana-de-açúcar na região de Mariana/MG.....	51

Figura 4.8 – Produtos de classificação pré-desastre antes e após a aplicação da máscara de água.....	52
Figura 4.9 – Mapa de cobertura da terra pré-desastre.....	52
Figura 4.10 – Concordância entre o mapa de cobertura da terra pré-desastre e os mapeamentos do Mapbiomas, ANA e SOS Mata Atlântica.....	54
Figura 4.11 – Classificação das séries temporais de NDVI pós-desastre.....	55
Figura 4.12 – Classificação das séries temporais de NDVI e métricas pós-desastre. ..	55
Figura 4.13 – Comparação entre as classificações para o período pós-desastre.....	56
Figura 4.14 – Importância de cada atributo utilizado nas classificações pós-desastre..	59
Figura 4.15 – Mapa de cobertura da terra do cenário pós-desastre.....	61
Figura 4.16 – Exemplo de cinco séries temporais de NDVI de áreas afetadas pelo desastre de Mariana.	64
Figura 4.17 – Séries temporais de NDVI definidas a partir de amostras coletadas em áreas de floresta afetadas pelo desastre.....	66
Figura 4.18 – Séries temporais de NDVI definidas a partir de amostras coletadas em áreas com presença de gramíneas e herbáceas antes do desastre e imagens dos diferentes cenários.	68
Figura 4.19 – Média e desvio padrão de nove séries temporais de NDVI referente a duas regiões afetadas pelo desastre (R1 e R2) e imagens das mudanças.	69
Figura 4.20 – Mapa da cobertura da terra incluindo a classe mudança.....	70
Figura 4.21 – Detalhamento das mudanças da cobertura da terra.....	71
Figura 4.22 – Identificação de áreas degradadas e áreas alagadas.	72
Figura 4.23 – Diagrama de Sankey das mudanças da cobertura da terra.....	73
Figura B. 1 – Imagens referentes à região de Bento Rodrigues e a série temporal de NDVI, a partir de amostras de áreas construídas.....	94

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Rompimentos de barragem no planeta.....	6
Tabela 2.2 – Rompimentos de barragem no Brasil.....	7
Tabela 2.3 – Índices de vegetação.....	17
Tabela 3.1 – Uso e cobertura da terra na bacia do rio do Carmo.....	30
Tabela 3.2 – Principais características dos sensores utilizados.....	32
Tabela 3.3 – Métricas extraídas a partir de séries temporais.....	35
Tabela 3.4 – Quantidade de imagens por classificação.....	36
Tabela 3.5 – Quantidade de amostras por classificação.....	37
Tabela 3.6 – Compatibilização das classes dos mapeamentos.....	39
Tabela 4.1 – Matriz de confusão da classificação pré-desastre das séries temporais de dados NDVI.....	45
Tabela 4.2 – Matriz de confusão referente à classificação pré-desastre das séries temporais de dados NDVI e métricas fenológicas.....	45
Tabela 4.3 – Matriz de confusão referente à classificação pré-desastre utilizando a série temporal de NDVI e métricas fenológicas.....	53
Tabela 4.4 – Matriz de confusão da classificação pós-desastre utilizando as séries temporais de NDVI.....	56
Tabela 4.5 – Matriz de confusão da classificação pós-desastre utilizando as séries temporais de dados NDVI e métricas fenológicas.....	57
Tabela 4.6 – Acurácias obtidas nas classificações.....	62

LISTA DE SIGLAS E ABREVIATURAS

AHP	<i>Analytic Hierarchy Process</i>
ANA	Agência Nacional de Águas
APA	Área de Preservação Ambiental
APP	Área de Preservação Permanente
ARVI	<i>Atmospherically Resistant Vegetation Index</i>
BFast	<i>Breaks For Additive Season and Trend</i>
BHP	<i>Broken Hill Proprietary Company Limited</i>
BT	<i>Boosted Tree</i>
CBERS	<i>China-Brazil Earth Resources Satellite</i>
CFMask	<i>Cloud Function Mask</i>
COBRADE	Classificação e Codificação Brasileira de Desastres
CP	Componentes Principais
CPRM	Companhia de Pesquisa de Recursos Minerais
EMATER	Empresa de Assistência Técnica e Extensão Rural
EM-DAT	<i>Emergency Database</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
EVI	<i>Enhanced Vegetation Index</i>
FEAM	Fundação Estadual do Meio Ambiente
GEE	<i>Google Earth Engine</i>
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais
IBGE	Instituto Brasileiro de Geografia e Estatísticas
IFD	<i>Iron Feature Depth</i>
INPE	Instituto Nacional de Pesquisas Espaciais
LaSRC	<i>Landsat 8 Surface Reflectance Code</i>
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
LMT	<i>Logistic Model Trees</i>
MAPBIOMAS	Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil
MARSpline	<i>Multivariate Adaptive Regression Spline</i>
MLME	Modelo Linear de Mistura Espectral

MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSI	<i>MultiSpectral Instrument</i>
MUX	Câmera multiespectral regular
NDVI	<i>Normalized Difference Vegetation Index</i>
OLI	<i>Operational Land Imager</i>
PVI	<i>Perpendicular Vegetation Index</i>
PIRH	Plano Integrado de Recursos Hídricos da Bacia do Rio Doce
QA	<i>Quality Assessment</i>
RF	<i>Random Forest</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SEMAD	Secretaria de Estado do Meio Ambiente e Desenvolvimento Sustentável
SISEMA	Sistema de Meio Ambiente do Estado de Minas Gerais
SLC	<i>Scan Line Corrector</i>
SR	Sensoriamento Remoto
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	<i>Support Vector Machine</i>
SWIR	<i>Short Wave Infrared</i>
TM	<i>Thematic Mapper</i>
TTAC	Termo de Transação e Ajuste de Conduta
UC	Unidades de Conservação
USGS	<i>United States Geological Survey</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos específicos	4
2 FUNDAMENTAÇÃO TEÓRICA.....	5
2.1 Desastres.....	5
2.1.1 Sensoriamento Remoto aplicado a desastres.....	8
2.1.2 Desastre de Mariana	10
2.1.3 Estudos relacionados ao desastre de Mariana	13
2.2 Índices de vegetação	16
2.3 Séries temporais	17
2.4 Métricas fenológicas	19
2.5 Mineração de dados.....	21
2.5.1 Random Forest.....	22
2.6 Avaliação da classificação	24
3 MATERIAL E MÉTODOS	27
3.1 Área de Estudo	27
3.2 Metodologia	31
3.2.1 Aquisição e pré-processamento de dados	32
3.2.2 Extração de métricas	35
3.2.3 Classificação utilizando o Random Forest	36
3.2.4 Pós-processamento.....	38
3.2.5 Validação do mapa de cobertura da terra pré-desastre	38
3.2.6 Análises das mudanças da cobertura da terra	40
4 RESULTADOS E DISCUSSÃO	43
4.1 Série temporal de NDVI	43
4.2 Classificação com Random Forest.....	43
4.2.1 Classificação pré-desastre.....	43
4.2.2 Pós-processamento e validação pré-desastre	50
4.2.3 Classificação pós-desastre	54
4.2.4 Pós-processamento da classificação pós-desastre.....	61

4.2.5	Comparação das classificações pré e pós-desastre	61
4.3	Análises de mudanças da cobertura da terra causadas pelo desastre	63
4.3.1	Séries temporais de NDVI nas áreas afetadas pelo desastre	63
4.3.2	Mudanças da cobertura da terra	70
5	CONCLUSÕES	75
	REFERÊNCIAS BIBLIOGRÁFICAS	77
	APÊNDICE A – Mapas utilizados para a validação da classificação pré-desastre	91
	APÊNDICE B – Complemento de análises da cobertura da terra causadas pelo desastre de mariana	93

1 INTRODUÇÃO

As atividades de mineração estão comumente associadas a impactos ambientais de diferentes magnitudes. O rompimento de barragens, geralmente, gera além de impactos ambientais como a poluição da água e do solo, episódios traumáticos com números elevados de mortes. Apesar de trágicos, estes acidentes são comuns no Brasil e no mundo. Nos últimos 10 anos foram contabilizados 43 acidentes desta categoria no Brasil (EM-DAT, 2020).

Minas Gerais é o estado brasileiro com maior número de barragens de contenção de rejeitos de mineração (ANA, 2016b). No ano de 2017, a Fundação Estadual do Meio Ambiente (FEAM) contabilizou 698 barragens cadastradas no estado de Minas Gerais, sendo que em uma escala de baixo (classe I), médio (classe II) e alto risco (classe III), mais de 200 destas pertencem a classe III com alto potencial de dano ambiental (FEAM, 2018). Nos últimos anos, alguns eventos de rompimento de barragens de rejeitos de mineração ocorreram no estado de Minas Gerais. Em 2014, houve o rompimento da barragem B1 em Itabirito (ANDRADE, 2014); em 2015, ocorreu o desastre em Mariana-MG com o rompimento da barragem de Fundão (ANA, 2016a); e, mais recentemente, em 2019, houve também o rompimento de uma barragem de rejeitos de mineração em Brumadinho (CNDH, 2019).

Estes rompimentos além de causarem mortes e ferimentos em massa (ALVES, 2019), também têm impactos sobre a qualidade da água (ANA, 2016a), na saúde (CARVALHO et al., 2017), na biodiversidade da flora e da fauna (RENOVA, 2016), e sobre o uso e cobertura da terra. Dentre os três eventos citados anteriormente, o desastre de Mariana teve o maior vazamento de rejeitos de mineração. De acordo com IBAMA (2015), cerca de 50 milhões de metros cúbicos de lama foram derramados. A lama atingiu aproximadamente 1600 ha (hectares), destruiu vilas, desalojou parte da população (PROUS, 2015), e percorreu 650 km de curso hídrico (ANA, 2016a). O vazamento de rejeitos causou a destruição de áreas de mata ciliar, construção, pastagem e áreas agrícolas. O desastre causou uma série de mudanças na cobertura da terra, tanto pelo impacto da lama, como por intervenções na tentativa da recuperação

de algumas áreas, posteriormente. Os rejeitos podem causar alterações físicas e químicas do solo, dificultando a recuperação destas áreas.

Estudos que fazem o acompanhamento destas mudanças, suas causas e efeitos, a curto e longo prazo, são necessários para subsidiar o planejamento de ações de intervenção para a preservação e/ou recuperação dos ambientes degradados. Por outro lado, o acompanhamento destas áreas em recuperação, observando suas mudanças ao longo do tempo, permite avaliar a eficácia das intervenções propostas e identificar estratégias adequadas. Neste contexto, torna-se relevante investigar e desenvolver novos métodos de obtenção de dados para a detecção de mudanças da cobertura da terra em diferentes períodos de tempo, com ampla cobertura espacial, com custos menores.

Vários trabalhos, vêm empregando técnicas de sensoriamento remoto, no sentido de classificar a cobertura da terra para a área de Mariana, usando interpretação visual de imagens (SOS e INPE, 2015), índices de vegetação (SILVA e SIQUEIRA, 2017) e diferentes classificadores (GAIAD, 2017). Alguns trabalhos também tem sido desenvolvidos com o objetivo de identificar mudanças da cobertura da terra (SILVEIRA, 2017), inclusive observar graus de degradação dessa cobertura (ALMEIDA et al., 2019). Apesar dos vários trabalhos já desenvolvidos com enfoque nesta área de estudo, nenhum destes explora o potencial da análise de séries temporais. Áreas afetadas pelo rompimento de barragens necessitam de acompanhamento por longos períodos de tempo para garantir a recuperação dos habitats degradados. E a utilização de séries temporais pode contribuir para as avaliações, pois permitem uma análise da dinâmica temporal de uma área, e não apenas de seu estado momentâneo.

As séries temporais de sensores com elevada frequência temporal já vêm sendo bastante aplicadas em diversos estudos, como as séries do sensor MODIS. Porém, estes sensores não apresentam uma resolução espacial compatível com as análises necessárias aos casos de rompimento de barragens. Para superar essa limitação, imagens de diferentes sensores orbitais são utilizadas na composição de séries temporais, nas chamadas abordagens multisensor (EVA; LAMBIN, 1998; SHIMABUKURO et al., 1999). Os índices de vegetação têm sido

bastante aplicados em estudos com séries temporais, por combinarem bandas de forma a ressaltar características da vegetação. Exemplos são o EVI (*Enhanced Vegetation Index*), e o NDVI (*Normalized Difference Vegetation Index*), um dos índices mais empregados em estudos da cobertura da terra, pois compensa parcialmente variações na intensidade da radiação, nos ângulos solares e de visada do sensor e em efeitos atmosféricos (LIU, 2007).

A utilização de séries temporais ainda é um campo que merece ser explorado. Atualmente, há a disponibilidade de coleções de imagens de diferentes sensores que podem compor as séries temporais. Porém, a quantidade de imagens, número de sensores, os critérios de seleção, e metodologias de processamento destes dados, para a criação de um cubo de imagens, ainda permitem uma série de discussões. A grande maioria dos trabalhos de séries temporais, apesar de trabalhar grandes conjuntos de dados na seleção das imagens, acabam descartando boa parte destes dados para criar séries temporais regularmente espaçadas no tempo. Este trabalho vai em sentido oposto, buscando a composição de uma série temporal densa, com o maior número possível de observações, mesmo que irregularmente espaçadas no tempo.

Neste contexto, o principal objetivo deste trabalho foi explorar o potencial de séries temporais de NDVI para o mapeamento da cobertura da terra, e para detectar e analisar as mudanças da cobertura da terra após o rompimento da barragem de Fundão em Mariana-MG. A metodologia desenvolvida tem como diferencial a busca por extrair informações a partir de séries temporais de NDVI, multisensor e densas, com o mínimo de processamento. A metodologia utiliza imagens de média resolução espacial dos sensores ETM+ do Landsat-7, OLI do Landsat-8, MUX do CBERS-4 e MSI do Sentinel-2 entre os anos 2013 a 2019 para compor a série temporal. Técnicas de classificação baseada no algoritmo *Random Forest* (RF) são usadas para gerar os mapas de cobertura da terra para os cenários de pré-desastre (2013-2015) e pós-desastre (2016-2019).

1.1 Objetivos específicos

- i) Analisar o potencial do uso de séries temporais de NDVI, densas e multisensor, sem processos de harmonização ou normalização, para mapeamentos da cobertura da terra;
- ii) Avaliar o desempenho do classificador *Random Forest* com séries temporais sobre áreas de ocorrência de desastre ambiental;
- iii) Avaliar a utilização de métricas fenológicas como atributos para a classificação de séries temporais, visando o mapeamento da cobertura da terra;
- iv) Verificar as limitações da aplicação de séries temporais compostas por dados multisensores com resolução espacial média (10 a 30 m) para analisar a cobertura da terra em áreas atingidas por desastres ambientais.

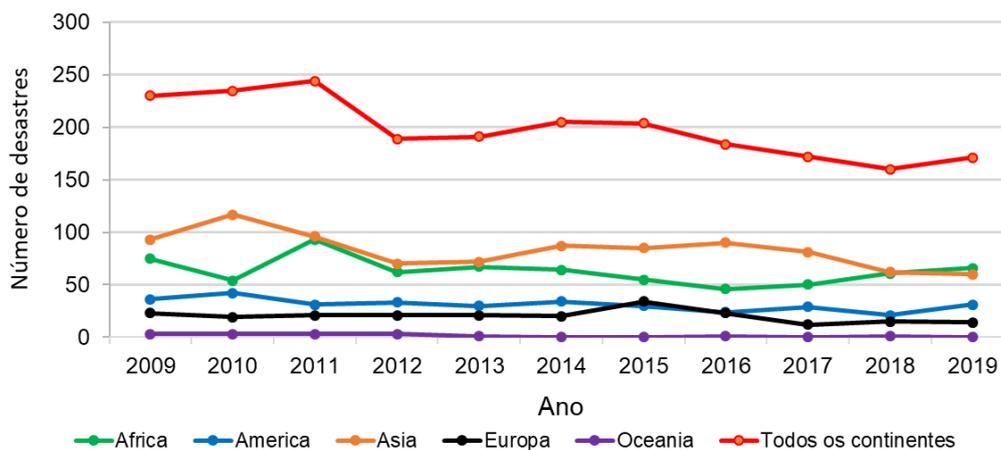
2 FUNDAMENTAÇÃO TEÓRICA

2.1 Desastres

Desastres são eventos que ocorrem dentro de uma comunidade, perturbam seu funcionamento normal causando vítimas e acarretando danos econômicos e/ou ambientais (SILVA et al., 2019). Segundo Marcelino (2008), os desastres classificam-se segundo o referencial teórico do fenômeno que lhes dão origem. A Classificação e Codificação Brasileira de Desastres (COBRADE) classifica os desastres no Brasil por categorias, grupos, subgrupos, tipos e subtipos. São adotadas duas categorias: desastres naturais e tecnológicos. Os desastres naturais são divididos nos grupos: geológico, hidrológico, meteorológico, climatológico e biológico. Os desastres tecnológicos são divididos nos grupos: substâncias radioativas, produtos perigosos, incêndios urbanos, obras civis e transporte de passageiros e cargas não perigosas (DEFESA CIVIL, 2019). O Rompimento de Barragens classifica-se na categoria desastre tecnológico e no grupo desastres relacionados a obras civis.

São inúmeros os desastres tecnológicos que ocorreram no Brasil e em outras partes do mundo. Segundo o Emergency Database (EM-DAT), no período de 2009 a 2019, foram contabilizados 2185 casos de desastres tecnológicos no mundo, sendo 43 casos no Brasil. E desses, 5 casos são de rompimento de barragens em território brasileiro. Observa-se na Figura 2.1 as ocorrências de desastres tecnológicos a partir de 2009.

Figura 2.1 – Número de desastres tecnológicos no mundo (2009 – 2019), segundo dados do EM-DAT.



Fonte: Produção do autor.

Segundo Alves (2019), o rompimento de barragens em diversas ocasiões foi responsável por danos ambientais, pela morte de centenas de pessoas e animais, além de inúmeros danos materiais pelo mundo. O maior desastre da história registrado foi a enchente do rio Huan He (Rio Amarelo) em 1887, conhecido como Tristeza da China, durante o qual ocorreu a ruptura dos diques do rio que levou à morte de 3 três milhões de pessoas. Essas mortes foram ocasionadas pelo fluxo da água, por afogamento e também por doenças causadas pela água da enchente. Em vários momentos, o rompimento de barragens foi o motivo de acidentes pelo mundo. Alves (2019) descreve os principais desastres de rompimento de barragem ocorridos no planeta (Tabela 2.1).

Tabela 2.1 – Rompimentos de barragem no planeta.

LOCAL	ANO	NOME	TIPO	DANOS CAUSADOS
Los Angeles (EUA)	1928	St. Francis	Barragem de água para abastecimento.	450 óbitos.
Riviera Francesa (FRA)	1959	Malpasset	Barragem de água para abastecimento.	Mais de 420 óbitos.
Dolomitas (ITA)	1963	Vajont	Barragem de água para geração de energia.	Entre 2000 e 2600 óbitos.
Virgínia (EUA)	1972	Barragem 3 da Companhia Pittson Coal.	Barragem de resíduos líquidos.	125 mortos, 1.121 feridos, aproximadamente 4.000 desabrigados.
Província de Henan (CHN)	1975	Banqiao	Barragem de água para controlar enchentes e gerar eletricidade.	25 mil óbitos pela enchente e 135 por consequências posteriores.
Idaho (EUA)	1976	Teton	Barragem de água para diversos propósitos, inclusive proteção contra enchentes.	11 óbitos.
Marinduque (FIL)	1996	Mogpog	Barragem de rejeitos de minério.	Não houve mortes diretas, mas vários óbitos por doenças relacionadas ao lixo tóxico, contaminação do Rio Boac e centenas de desabrigados.
Quebec (CAN)	1996	Há!Há!	Barragem de água.	Entre 7 e 10 óbitos. 16 mil pessoas foram evacuadas, 488 casas destruídas.
Andaluzia (ESP)	1998	Barragem da Boliden	Barragem de resíduos de zinco, ferro e cádmio.	Danos ambientais de longo prazo. Mortalidade de peixes e poluição do rio Guadiamar.
New Orleans (EUA)	2005	Sistema federal de diques	Barragem de água.	1836 óbitos e 705 desaparecidos em decorrência do furacão Katrina. Não há informações relacionadas especificamente ao rompimento dos diques,

Fonte: Alves (2019).

O Brasil também tem, em sua história, diversos desastres por rupturas de barragens nos últimos 35 anos (Tabela 2.2). Pode-se observar que mais de 58% desses desastres ocorreram no estado de Minas Gerais, na região conhecida como “quadrilátero ferrífero”. Os mais recentes rompimentos foram nas Barragens do Fundão, na cidade de Mariana, e na Barragem da Mina do Córrego do Feijão em Brumadinho. Ambas as cidades estão localizadas em Minas Gerais. Minas Gerais é o estado brasileiro que mais possui barragens de rejeitos, o que decorre da grande exploração mineral.

Tabela 2.2 – Rompimentos de barragem no Brasil.

LOCAL	ANO	NOME	TIPO	DANOS CAUSADOS
Itabirito (MG)	1986	Barragem de Fernandinho	Barragem de rejeitos minerários.	7 óbitos.
Nova Lima (MG)	2001	Barragem de Macacos	Barragem de rejeitos minerários.	5 óbitos.
Cataguases (MG)	2003	Barragem em Cataguases	Barragem de rejeitos industriais.	Contaminação do rio Paraíba do Sul, morte de animais e interrupção do abastecimento de água de 600.000 pessoas.
Alagoa Nova (PB)	2004	Camará	Barragem de água.	5 óbitos e aproximadamente 3 mil pessoas desabrigadas.
Miraí (MG)	2007	Barragem da Rio Pomba/ Cataguases	Barragem de rejeitos minerários.	Mais de 4000 pessoas desabrigadas ou desalojadas.
Vilhena (RO)	2008	Apertadinho	Barragem de água para geração de energia.	Danos ambientais variados (assoreamento de rios, erosão do solo, entre outros).
Cocal e Buriti dos Lopes (PI)	2009	Algodões	Barragem de água.	Entre 9 e 24 mortos e aproximadamente 2000 pessoas ficaram desabrigadas ou desalojadas.
Laranjal do Jari (AP)	2014	Santo Antônio	Barragem de água para geração de energia.	4 óbitos.
Itabirito (MG)	2014	Barragem da Herculano	Barragem de rejeitos minerários.	3 óbitos.

continua

Tabela 2.2 – Conclusão.

LOCAL	ANO	NOME	TIPO	DANOS CAUSADOS
Mariana (MG)	2015	Barragem Fundão	Barragem de rejeitos minerários.	19 óbitos, 8 desaparecidos, 600 desabrigados, interrupção do abastecimento de água e da atividade pesqueira, poluição do rio Doce e mar no ES, afetou o Turismo em Regência/ES.
São José do Rio Claro (MT)	2018	Barragens de uma pequena hidrelétrica	Barragem de água.	Nenhum óbito, queda de uma ponte e destruição da vegetação marginal de um trecho do rio Arinos.
Brumadinho (MG)	2019	Barragem da Minas do Córrego do Feijão	Barragem de rejeitos minerários.	259 óbitos, 11 desaparecidos, centenas de desalojados, afetou o Turismo pela interdição do museu Inhotim.

Fonte: Adaptado de Alves (2019).

2.1.1 Sensoriamento Remoto aplicado a desastres

Nas aplicações do SR voltadas a desastres é importante destacar tanto estudos de antecipação e emissão de alertas a desastres, quanto de detecção de mudanças e monitoramento da área. Para criação de estratégias que minimizem possíveis danos causados por desastres é importante a execução de mapeamentos de risco e susceptibilidade, além do monitoramento de grandes estruturas e modelagem de cenários futuros. Após a ocorrência de um desastre se faz importante a identificação de áreas afetadas, a caracterização da área e das mudanças sofridas, além do seu monitoramento. A coleta constante e sistemática de dados orbitais favorece este tipo mapeamento. Técnicas de Sensoriamento Remoto (SR) viabilizam o mapeamento de áreas extensas de forma rápida e a baixo custo. Dados de SR possibilitam o mapeamento de áreas de risco, a realização de avaliações quantitativas e qualitativas de áreas de desastres ambientais, podendo auxiliar na definição de planos de recuperação e na avaliação de áreas regeneradas. A seguir são apresentados alguns trabalhos que aplicam o SR nesta temática.

Taalab et al. (2018) apresentam uma abordagem *Random Forest* (RF) para gerar mapas de suscetibilidade a deslizamentos de terra em larga escala, na região do Piemonte, na Itália. É uma região heterogênea e com diferentes tipos de movimentos de massa. A partir do modelo RF, os autores obtiveram uma

acurácia acima de 85% e demonstraram a eficácia desse algoritmo na produção de mapas de suscetibilidade altamente precisos para uma grande região heterogênea sem a necessidade de múltiplas avaliações de suscetibilidade.

O RF também foi utilizado nos trabalhos de Chen et al. (2017), Chu et al. (2018) e Kim et al. (2018). Chen et al. (2017) comparam o desempenho de três modelos: Logistic Model Tree, RF e Classification and Regression Tree. A acurácia do RF foi maior que dos demais modelos (83.7%), demonstrando, assim, bom desempenho para este tipo de mapeamento. Chu et al. (2018) utilizaram os modelos RF e *Multivariate Adaptive Regression Spline* (MARSpline) para mapear as áreas suscetíveis a deslizamentos de terra na cidade de Gero, no Japão. Como resultado, o RF apresentou maior acurácia. Kim et al. (2018) utilizaram o RF e o Boosted Tree (BT) para mapeamento de suscetibilidade a deslizamentos de terra em Pyeong-Chang, na Coreia do Sul. Para o modelo RF, a precisão da validação nos algoritmos de regressão e classificação mostrou 79,34% e 79,18%, respectivamente. Para o modelo BT, estes resultados foram 84,87% e 85,98%, respectivamente. De acordo com os autores, os dois modelos apresentaram precisão satisfatória. O modelo BT apresentou melhores resultados do que o modelo RF.

Mielke et al. (2014) propuseram um índice, chamado de IFD (*Iron Feature Depth*), para monitorar áreas de mineração na África. Este índice foi testado para vários sensores, hiperespectrais e multiespectrais (e.g. Landsat-8/OLI e Sentinel-2), apresentando bons resultados na identificação de rejeitos de mineração. Hamuna et al. (2019) analisaram mudanças na densidade da vegetação de manguezais de áreas afetadas, em 1996, por um Tsunami na Indonésia. Para identificar as mudanças, os autores utilizaram imagens Landsat-5/TM, de 1994, e Landsat-7/ETM+, de 2000. Os níveis de densidade da vegetação foram dados pela variação do NDVI. Foram gerados mapas da distribuição e densidade da vegetação de manguezais, por meio de classificação por Máxima Verossimilhança. Nesta análise, eles identificaram uma diminuição significativa da vegetação, principalmente da vegetação densa.

2.1.2 Desastre de Mariana

As atividades da Samarco Mineração S.A. foram iniciadas no ano de 1977 no município de Mariana/MG. Para o depósito de sedimentos de mineração, a partir de 2008, a empresa passou a utilizar a barragem do Fundão, localizada a aproximadamente 5 km à jusante do distrito de Bento Rodrigues, com altura de 100 m, comprimento de 761 m e volume armazenado da ordem 41 milhões de m³. A barragem foi classificada como classe III, de alto potencial de dano ambiental. Além dessa barragem, o complexo tem a barragem do Germano, a cava do Germano, que foi utilizada para depositar o rejeito arenoso. A barragem de Santarém, localizada à jusante das barragens do Germano e do Fundão, era utilizada para contenção de sedimentos e como reservatório de água (PEDROSA, 2017). A Figura 2.2 identifica as barragens de rejeito utilizadas no empreendimento.

Figura 2.2 – Barragens de responsabilidade da empresa Samarco Mineração S/A.

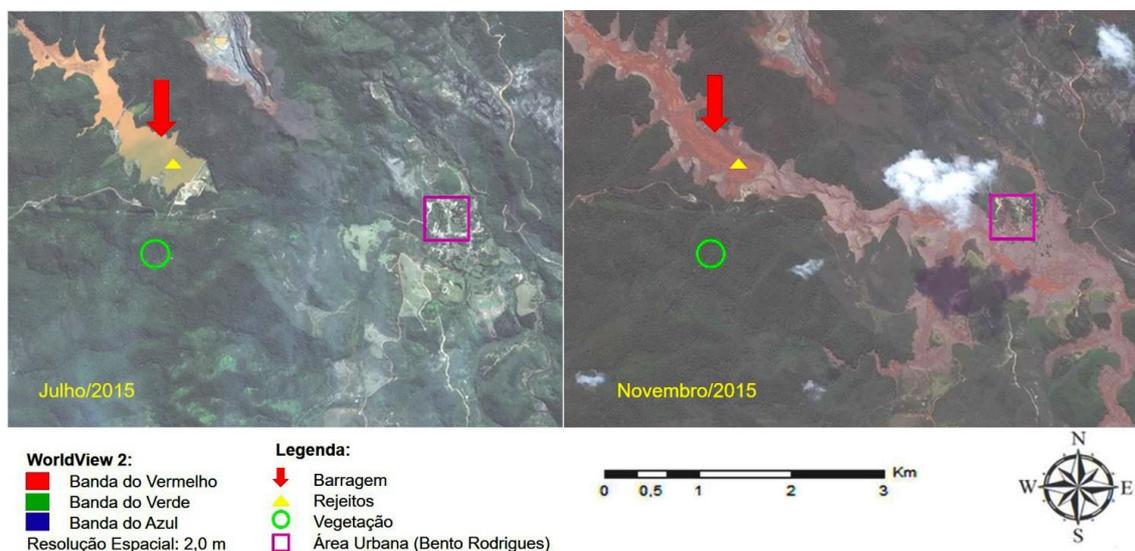


Fonte: Pedrosa (2017).

No dia 5 de novembro de 2015, houve o rompimento da barragem de Fundão. A lama de Fundão atingiu a barragem de Santarém, causando o galgamento da mesma, que não chegou a se romper por completo (LOPES, 2016). De acordo com

o relatório feito pelo IBAMA, foram derramados mais de 50 milhões de m³ de rejeitos (IBAMA, 2015). A lama devastou o distrito de Bento Rodrigues, seguiu os cursos do córrego Santarém e rios Gualaxo do Norte e do Carmo por 77 km até alcançar o rio Doce. Ao todo, a lama percorreu mais de 650 km até a foz do rio Doce, em Linhares, no litoral do Espírito Santo (ANA, 2016a). Ao todo foram afetadas 35 cidades de Minas Gerais, e 3 do Espírito Santo (GRUPO DA FORÇA TAREFA, 2016). A Figura 2.3 mostra o antes e depois do desastre na região próxima à barragem.

Figura 2.3 – Imagens WorldView-2 pré e pós-desastre de Mariana.



Fonte: Produção do autor.

A lama provocou a morte de mais de 11 toneladas de peixes, ameaçou a extinção de algumas espécies, impactou fauna, flora, áreas marítimas, áreas de preservação permanente e de conservação. Causou prejuízos ao patrimônio, às atividades pesqueira, agropecuária, turismo e lazer na região (ANA, 2016b). Os rejeitos liberados no rompimento da barragem apresentaram metais pesados, sendo encontrados traços de chumbo, arsênio, cobre, níquel, alumínio e manganês (CARVALHO et al., 2017). A presença destes metais e a movimentação de massas afetou o solo; influenciou nas movimentações de bancos de sementes, o que coloca em risco o processo de sucessão natural da vegetação; destruiu completamente a vegetação rasteira e arbustiva.

Segundo o Grupo da Força Tarefa (2016), na região das barragens de Santarém e Fundão, até parte do Rio Gualaxo do Norte em direção ao Rio do Carmo,

estimaram-se um impacto em 560,35 ha de cobertura vegetal. Dessa cobertura 384,71 ha seriam de Mata Atlântica. Nas áreas adjacentes seguindo o prolongamento do Rio Gualaxo do Norte em direção à foz do Rio Doce, estimaram-se 1.026,65 ha de cobertura vegetal atingida, com 126,37 ha de Mata Atlântica.

Ações de recuperação e de acompanhamento das áreas afetadas vêm sendo feitas na tentativa de minimizar os impactos ambientais causados pelo rompimento da barragem de Fundão, em Mariana-MG. A Fundação Renova, criada em março de 2016, pelo Termo de Transação e Ajuste de Conduta (TTAC), assinado entre Samarco, Vale, BHP (*Broken Hill Proprietary Company Limited*), Governo Federal e Governos dos Estados de Minas Gerais e Espírito Santo, tem realizado várias ações de recuperação das áreas afetadas (FUNDAÇÃO RENOVA, 2016). Os Planos de recuperação da bacia do Rio Doce criados envolvem atividades tais como enrocamento, hidrossemeadura emergencial, plantios de mudas/sementes; instalação de biomantas; reconformação de taludes; outros controles de erosão (SISEMA, 2016).

O TTAC determina que sejam recuperadas 5 mil nascentes em até 10 anos. Até outubro de 2018, a Renova realizou ações de recuperação da vegetação em 1.043 nascentes, das quais 511 foram protegidas, por meio de cercamentos. Na primeira fase de recuperação da vegetação, que ocorreu no período de 2016 até o primeiro semestre de 2017, foram plantadas espécies de crescimento rápido, tais como gramíneas e leguminosas, como medida de emergência para estabilização dos rejeitos. Na segunda fase, foi introduzida a plantação de vegetação nativa do bioma Mata Atlântica nas margens dos rios, para substituir a vegetação rasteira (FUNDAÇÃO RENOVA, 2016).

Para acompanhar as ações de recuperação, o Sistema de Meio Ambiente do Estado de Minas Gerais (SISEMA) criou a operação Watu, que já realizou nove operações de vistoria, cujos relatórios foram disponibilizados no site da Secretaria de Estado do Meio Ambiente e Desenvolvimento Sustentável - SEMAD¹. A Figura 2.4 apresenta um ponto atingido pelos rejeitos da barragem

¹ <http://www.meioambiente.mg.gov.br/component/content/article/13-informativo/3036-relatorio-watu-fase-i>

de Fundão e acompanhado pela Operação Watu (Watu – nome dado ao rio pelos índios Krenak). Segundo o SISEMA (2020), nesse trecho, em registros de operações anteriores, a vegetação encontrava-se em desenvolvimento. Em contraposição, a vistoria de campo da Operação - fase IX apresentou estabilidade das margens, mas com intensa sobreposição de espécies invasoras, como braquiária, não sendo observada vegetação arbustiva ou em desenvolvimento típico da vegetação nativa. Diante desse cenário, foi recomendado o manejo da braquiária para inserção de mudas nativas. Avaliações como esta são realizadas em 12 trechos, divididos ao longo da área atingida pela lama e considerados de recuperação prioritária (SISEMA, 2020).

Figura 2.4 – Trecho fiscalizado pela Operação Watu.



Fonte: SISEMA (2020).

2.1.3 Estudos relacionados ao desastre de Mariana

Alguns estudos para o monitoramento da dinâmica da cobertura da terra na bacia do Rio Doce foram realizados após o rompimento da barragem de Fundão. Nesses estudos, imagens de sensores orbitais e índices de vegetação foram

utilizados para extrair informações referentes ao relevo, áreas de ocupação, tipos de cobertura vegetal, entre outros. Alguns dos estudos já realizados nesta temática são apresentados neste Capítulo.

O mapeamento realizado pelo SOS Mata Atlântica e INPE (2015) identificou mudanças nos remanescentes florestais de Mata Atlântica em um trecho da área afetada, que se estende da barragem de Fundão até a Represa da Usina da Candonga. Esta área abrange um total de 114 km de cursos hídricos, 12 km do Rio Doce, 28 km do Rio do Carmo, 69 do Rio Gualaxo do Norte, 3 km do córrego Santarém e 2 km do afluente do córrego Santarém. Esse mapeamento foi realizado por interpretação visual de imagens orbitais do sensor Landsat-8/OLI para datas pré-desastre (25 de setembro 2015) e pós-desastre (12 de novembro de 2015). De acordo com os resultados, no trecho analisado, foi removida uma área de 236 ha de remanescentes florestais e 88 ha de vegetação natural da Mata Atlântica.

Da Silva e Siqueira (2017) utilizaram imagens Landsat, obtidas pelos sensores TM e OLI, na avaliação da cobertura da terra da Bacia do Rio Doce. Os autores analisaram os anos de 1987, 1997, 2007, 2016. Nesta análise foram utilizados os índices NDVI e SAVI (*Soil Adjusted Vegetation Index*) para avaliar as mudanças entre vegetação densa, vegetação rasteira e solo exposto. Os resultados mostraram perda significativa de vegetação ao longo do tempo, com destaque para o ano de 2016. Este ano apresentou praticamente 100% da região com vegetação rasteira ou solo exposto, mostrando assim uma grande degradação do ecossistema base nas regiões de margem do Rio Doce.

Almeida et al. (2018) fizeram uma análise multicritério para avaliar a prioridade de recuperação de áreas degradadas em uma porção (~24% da área) da Bacia do Rio Doce utilizando imagens *RapidEye*. A análise usou o Processo de Análise Hierárquica (AHP - *Analytic Hierarchy Process*) e levou em conta dados climáticos, de solo, de declividade e de drenagem. Os resultados mostraram perdas na vegetação próximas aos cursos hídricos e identificaram que 65% da área analisada tem necessidade de recuperação de média a muito alta.

Silva Júnior et al. (2018) aplicaram o MLME (Modelo Linear de Mistura Espectral, para separar solo, sombra e vegetação para a detecção e análise de mudanças da cobertura da terra no desastre de Mariana. O trabalho usou duas imagens Landsat-8/OLI: uma de 27 de junho de 2015 (pré-desastre) e outra de 26 de julho de 2016 (pós-desastre). As análises foram concentradas nos primeiros 40 km do trecho do desastre, nos quais os autores detectaram o aumento da área referente à classe solo e a diminuição de área correspondente às classes vegetação e sombra, entre os cenários pré e pós-desastre. O trabalho usou os índices NDVI e EVI cujos valores médios foram diminuídos, sendo que os valores pós-desastre se aproximaram de zero para ambos os índices, devido à remoção da cobertura vegetal.

Silveira et al. (2017) detectaram as mudanças da cobertura da terra no município de Mariana-MG por meio de um conjunto de índices calculados de semivariogramas derivados de imagens NDVI. O processo iniciou-se com a aquisição de imagens Landsat 8, antes do desastre (outubro de 2015) e após o desastre (novembro de 2015). Os objetos foram criados através da segmentação em multiresolução baseada na imagem pós-desastre. O trabalho usou índices de semivariogramas para obter informações de textura dos objetos, e aplicou CP (Componentes Principais) para auxiliar na interpretação e seleção dos atributos. Também foi aplicado o algoritmo SVM (*Support Vector Machine*) na classificação e avaliação dos resultados, que foram comparados a mapas obtidos por interpretação visual. Esta avaliação mostrou uma relação entre a ocorrência de mudanças da cobertura e os semivariogramas selecionados na análise, destacando o potencial de análise do NDVI na detecção de mudanças da cobertura da terra.

Gaiad (2017) testou diferentes classificadores para classificar a cobertura da terra no município de Mariana-MG. As classes consideradas foram sombra, nuvem, vegetação, lama, solo/mineração e água. Os classificadores testados foram árvore de decisão, LMT (Logistic Model Trees), RF, *Random Tree*, REPTree e J48. Os melhores resultados foram obtidos para o LMT, RF e *Random Tree* os quais não apresentaram diferenças significativas entre si. Os valores de acurácia global encontrados variaram de 92% a 98%.

Estes estudos aplicaram diferentes técnicas de SR e diferentes tipos de dados na caracterização do uso e cobertura da terra na região afetada pelo desastre de Mariana, ou das mudanças de uso e cobertura desta área. Porém, pode-se perceber que estes estudos não exploraram o potencial da análise de séries temporais, como proposto neste trabalho.

2.2 Índices de vegetação

A vegetação apresenta diferentes fases fenológicas, tendo variações na sua estrutura e pigmentos, conforme os estágios de crescimento e a saúde da planta, que impactam diretamente na resposta espectral do alvo (NOVO, 2010). As folhas apresentam comportamentos espectrais distintos nos comprimentos de onda do visível e infravermelho próximo do espectro eletromagnético. Desta forma, este comportamento pode ser usado para realçar a presença da vegetação nas imagens por meio dos chamados índices de vegetação. De acordo com Jackson e Huete (1991), estes índices podem ser calculados por meio da razão entre bandas ou em combinação linear, e são a forma mais simples de realce da vegetação. Diversos índices têm sido propostos na literatura (LIU, 2007), sendo os mais utilizados o NDVI, PVI, SAVI, ARVI e EVI, os quais estão descritos na Tabela 2.3. Mais detalhes sobre estes e outros índices de vegetação podem ser encontrados em Ponzoni et al. (2012).

Liu (2007) destaca que as aplicações de índices de vegetação no mapeamento de uso da terra têm algumas vantagens, pois compensam parcialmente variações na intensidade da radiação, nos ângulos solares e de visada do sensor e em efeitos atmosféricos. O índice NDVI é um dos mais usados para analisar a cobertura vegetal. As análises de mudanças da cobertura da terra realizadas neste trabalho utilizaram o NDVI, desenvolvido por Rouse Junior et al. (1974). Este índice varia de -1 a 1, onde valores negativos de NDVI correspondem a água e nuvens, próximos de 0 correspondem a superfícies não vegetada, e valores mais próximos de 1 evidenciam a vegetação verde e sadia (PONZONI et al., 2012).

Por meio de séries temporais do NDVI é possível extrair métricas fenológicas que indicam o comportamento da vegetação, que pode ser comparado entre anos distintos. Além disso, as séries temporais do NDVI criam perfis temporais que auxiliam na análise da dinâmica da vegetação. Estes perfis temporais são

aplicados, por exemplo, em estudos da sazonalidade da vegetação, ou na detecção de suas diferentes etapas fenológicas, identificando os períodos de crescimento, picos de verde e fase de senescência (MOREIRA, 2011; PONZONI et al., 2012) e em diversos outros estudos.

Tabela 2.3 – Índices de vegetação.

VI	Equação*	Autores
<i>Normalized Difference Vegetation Index (NDVI)</i>	$NDVI = \frac{(\rho IV - \rho V)}{(\rho IV + \rho V)}$	Rouse Junior et al. (1974)
<i>Perpendicular Vegetation Index (PVI)</i>	$PVI = \frac{1}{\sqrt{(a^2 + 1)}}(\rho IV - a * \rho V - b)$	Richardson e Wiegand (1977)
<i>Soil Adjusted Vegetation Index (SAVI)</i>	$SAVI = \frac{(1 + L)(\rho IV - \rho V)}{(\rho IV + \rho V + L)}$	Huete (1988)
<i>Atmospherically Resistant Vegetation Index (ARVI)</i>	$ARVI = \frac{(\rho IV - \rho V \rho A)}{(\rho IV + \rho V \rho A)}$ Onde: $\rho V \rho A = \rho V - \gamma (\rho A - \rho V)$	Kaufman e Tanré (1992)
<i>Enhanced Vegetation Index (EVI)</i>	$EVI = G \frac{(\rho IV - \rho V)}{(\rho IV + C_1 * \rho V - C_2 * \rho A + L)}$	Huete et al. (2002)

* ρIV = Reflectância no infravermelho; ρV = reflectância no vermelho; L = ajuste da linha do solo; G = fator de ganho (2,5); C_1 e C_2 são coeficientes de resistência de aerossóis, dados por 6 e 7,5 respectivamente; ρA = reflectância no Azul; “ a ” e “ b ” são parâmetros da linha do solo; γ = Depende do tipo de aerossol e tem como objetivo reduzir o efeito atmosférico.

Fonte: Produção do autor.

Vários autores têm utilizado séries temporais de índices de vegetação em diferentes aplicações. Por exemplo, Anderson et al. (2005) aplicaram o MLME associado aos índices NDVI e EVI na detecção de cicatrizes de queimadas. Couto Junior et al. (2012) também aplicaram estes dois índices na discriminação de áreas agrícolas. Bendini et al. (2017) e Bendini (2018) utilizaram séries temporais de EVI para identificação de diferentes culturas agrícolas, enquanto que Vrieling et al. (2011) utilizaram NDVI para analisar a dinâmica da agricultura na África. Como exemplo final, Jacquín et al. (2010) observaram a degradação de vegetação em Madagascar, aplicando análises de tendência em séries temporais de NDVI.

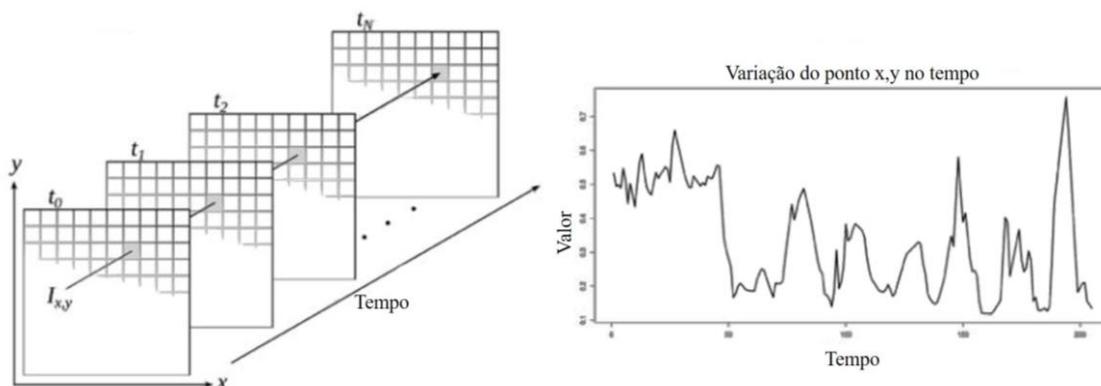
2.3 Séries temporais

As séries temporais têm sido bastante aplicadas em estudos da vegetação, pois a variação das características fenológicas das plantas permite a discriminação de

diferentes tipos de vegetação. Uma série temporal pode ser definida como um conjunto de observações de uma mesma região, ordenadas no tempo (MELAAS et al., 2013; MORETTIN; TOLOI, 2006; SAKAMOTO et al., 2005;). As séries temporais de índices de vegetação, como NDVI ou EVI (*Enhanced Vegetation Index*) a partir de dados MODIS (*Moderate Resolution Imaging Spectroradiometer*) tem sido bastante explorados com este propósito (ARVOR et al., 2011; COUTINHO et al., 2013; SAKAMOTO et al., 2005; WARDLOW et al., 2007).

As séries temporais de imagens orbitais permitem observar a variação na superfície terrestre em longos períodos de tempo, por meio do comportamento do alvo. A Figura 2.5 ilustra a variação de um pixel de uma série temporal. Segundo Brockwell e Davis (2002), séries temporais podem ser utilizadas para compreender a dinâmica temporal e espacial da cobertura da terra, assim como os fatores que controlam tais dinâmicas e variações, sejam relacionadas à fenômenos naturais ou antrópicos.

Figura 2.5 – Variação do pixel em uma série temporal de imagens NDVI.



Fonte: Adaptada de Maus (2013).

As séries temporais têm sido aplicadas na identificação de culturas agrícolas (BENDINI, 2018; COUTO JUNIOR et al., 2012; PETITJEAN et al., 2012) e nos estudos da sazonalidade da vegetação (JÖNSSON; EKLUNDH, 2002; VERBESSELT et al. 2012) e de suas fitofisionomias (CARVALHO et al., 2008; GIROLAMO NETO et al., 2015). Em estudos da vegetação, existem várias abordagens com séries temporais, como análises da fenologia (MELAAS et al., 2013; VERBESSELT et al., 2010a; VERBESSELT et al., 2010b), análises da

textura, aplicação por Componentes Principais (CP) e a utilização de métricas sobre índices de vegetação (HUETE et al., 2002), como o NDVI.

Aplicada no mapeamento de mudanças de uso e cobertura da terra as séries temporais podem detectar, por exemplo, desflorestamentos, queimadas, e as mais diversas transições de uso e cobertura da terra. As alterações da paisagem são refletidas em alterações dos valores dos índices de vegetação. Porém, a presença de ruídos na série temporal representa um desafio, pois estes podem afetar a detecção de mudanças ou até mesmo criar fenômenos irreais (ARANTES, 2014). Diversos estudos sobre análises temporais da dinâmica da cobertura da terra têm sido realizados, como os de Adami et al. (2008), Formigoni et al. (2011), Lhermitte et al. (2011), Peña e Ulloa (2017) e Rudorff et al. (2009).

Muller et al. (2015) aplicaram séries temporais e o algoritmo de *RF* para classificar uso e cobertura da terra em áreas de Cerrado no estado do Mato Grosso. Os autores usaram uma série temporal de imagens dos sensores Landsat TM e ETM+ no período de 2009 a 2012, considerando seis classes: Savana, Floresta, Áreas agrícolas, Pastagem cultivada, Corpos d'água e Áreas não vegetadas. Como atributos de classificação foram utilizados a média, mediana, desvio padrão, quartil de 75%, amplitude interquartil das bandas e o índice SWIR. A classificação teve uma taxa de acerto média de 93%.

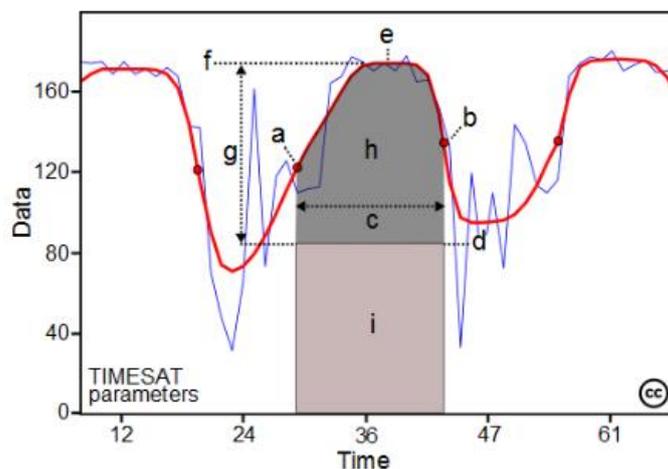
2.4 Métricas fenológicas

As técnicas de análises da mudança da cobertura da vegetação são baseadas na reflectância da vegetação, que varia conforme sua estrutura foliar, quantidade de clorofila, presença de água, e efeitos de fundo, etc. Desta forma, a fase fenológica das plantas, bem como as condições climáticas, modificam sua resposta espectral (SOUDANI et al., 2012). Estudos ecológicos têm mostrado que a fenologia da vegetação tende a seguir padrões relativamente bem definidos (ZHANG et al., 2003). Portanto, métricas fenológicas podem auxiliar na diferenciação destes padrões, auxiliando na identificação de áreas de vegetação e na sua classificação.

Algumas metodologias e algoritmos computacionais têm sido implementados para extrair informações de séries temporais de imagens orbitais, como o software TIMESAT (JÖNSSON; EKLUNDH, 2004), e o pacote de Python

stmetrics (SOARES, 2020 no prelo). As métricas fenológicas definidas no software TIMESAT podem ser extraídas a partir de séries temporais de imagens de satélites, como ilustra a Figura 2.6.

Figura 2.6 – Métricas fenológicas extraídas pelo TIMESAT (espectro esquemático).



Os pontos (a) e (b) marcam o início e o final do ciclo sazonal, respectivamente. Os pontos (c) e (d) representam o nível de 80% de distribuição dos dados. O ponto (e) mostra o máximo valor; (f) é a amplitude sazonal e (g) é a duração da estação. As integrais (h) e (i) mostram o efeito cumulativo de crescimento da vegetação no período. Fonte: Jönsson e Eklundh (2015).

Existem várias métricas fenológicas dentre as quais se destacam: média, utilizada para identificar presença constante de vegetação; amplitude, adotada para verificar a intensidade da evolução da vegetação entre períodos seco e chuvoso; e, desvio-padrão, utilizado para verificar a variação dos ciclos fenológicos. Além destes, outras estatísticas são adotadas, tais como os valores máximo e mínimo. Estas métricas têm sido bastante empregadas em mapeamentos de culturas agrícolas, porque podem identificar etapas como o início do plantio, colheita e intervalo de cultivo.

Estas métricas capturam informações fenológicas importantes e podem ser analisadas de forma sazonal, anual ou multianual permitindo várias aplicações para caracterizar sistemas de uso da terra no espaço e no tempo (MULLER, 2015). A utilização de métricas fenológicas tem se tornando cada vez mais comum para estudos de uso e cobertura da terra, tanto que USGS já fornece um

banco de dados de métricas fenológicas extraídas do produto NDVI do MODIS para todo o território dos Estados Unidos (USGS, 2019).

Segundo Huete et al. (2002), o TIMESAT pode ser usado tanto com o NDVI quanto com o EVI. Padovani (2010) criou imagens de fração de solo, de água e de vegetação (MLME) e realizou a suavização e preenchimento de falhas na série temporal dessas imagens e também nas imagens formadas pelos índices NDVI e EVI, utilizando o software TIMESAT com filtro adaptativo Savitzky-Golay. Bendini (2018) utilizou séries temporais de EVI, de imagens dos sensores Landsat-7/ETM+, Landsat-8/OLI e CBERS-4/MUX, e métricas fenológicas extraídas pelo TIMESAT para classificação de culturas agrícolas no cerrado brasileiro. Tan et al. (2011), Borges (2014), Borges et al. (2014), Bayma (2015) e Teles (2015) também utilizaram o TIMESAT com dados NDVI e/ou EVI.

Aguado (2017) avalia as características sazonais e de tendências em relação aos fatores condicionantes da degradação de pastagens na microrregião de São Miguel do Araguaia - GO. A metodologia consistiu na análise do vigor vegetativo de pastagens em três níveis de degradação com base no NDVI de imagens do sensor MODIS para o período de 2000 a 2015. A série temporal foi analisada utilizando métricas (máxima, mínima, média e amplitude) e o algoritmo *Breaks For Additive Season and Trend* (BFAST) para análise de tendências e identificação dos fatores de degradação.

2.5 Mineração de dados

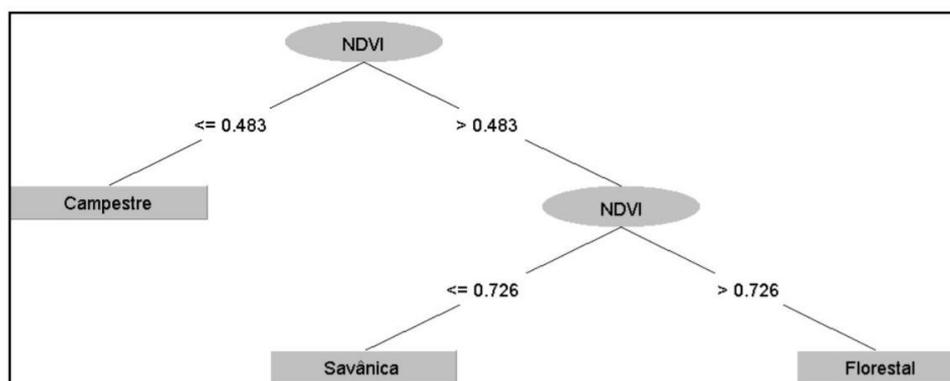
Devido ao grande volume de dados adquiridos por sistemas sensores, diversas técnicas computacionais foram desenvolvidas e/ou aperfeiçoadas nos últimos anos para reconhecer padrões e tendências, incluindo o processo de mineração de dados. A mineração de dados consiste na exploração de grandes conjuntos de dados a partir da especificação de métodos que permitam identificar padrões consistentes entre os atributos analisados (AMO, 2004). Dentre as principais técnicas utilizadas estão as técnicas estatísticas, redes neurais, lógica fuzzy e árvores de decisão (GOLDSCHMIDT; PASSOS, 2005). No SR, a mineração de dados tem sido utilizada na extração de informações espaciais e espectrais de séries temporais para a classificação de imagens (KÖRTING, 2012).

Os objetivos principais da mineração de dados são a descrição das propriedades gerais encontradas nos dados, com base em padrões que podem ser interpretados, e a predição de padrões, a qual usa variáveis com valores conhecidos para prever novos dados. Este processo é geralmente dividido em tarefas de classificação e regressão (FAYYAD et al., 1996; HAN et al., 2011). De forma geral, o processo de classificação visa categorizar dados em relação a um determinado conjunto de classes, a partir da utilização ou não de amostras rotuladas para treinamento do modelo. Nesse trabalho, o processo de classificação é realizado com ênfase no classificador *RF*.

2.5.1 Random Forest

O algoritmo *Random Forest* (RF) é um classificador supervisionado de *machine learning*, cuja classificação é baseada na criação de várias árvores de decisão. Uma árvore de decisão busca, com base nos atributos das amostras, segregar os dados em um determinado número de classes (APTE; WEISS, 1997). A árvore de decisão é representada por nós e ramos (WITTEN et al., 2011). A Figura 2.7 apresenta um exemplo de árvore de decisão. Nesse caso, a árvore foi gerada para a classificação de fitofisionomias de Cerrado em função de valores do NDVI (GIROLAMO NETO, 2018). O primeiro nó é denominado de nó raiz, sendo este o nó principal da árvore de decisão. Abaixo dos nós raízes estão localizados os nós filhos, os quais estão conectados por ramos. Ao final da árvore estão localizados os nós folhas, as quais representam as regiões associadas a um valor (SOBRAL, 2003; AITKENHEAD, 2008).

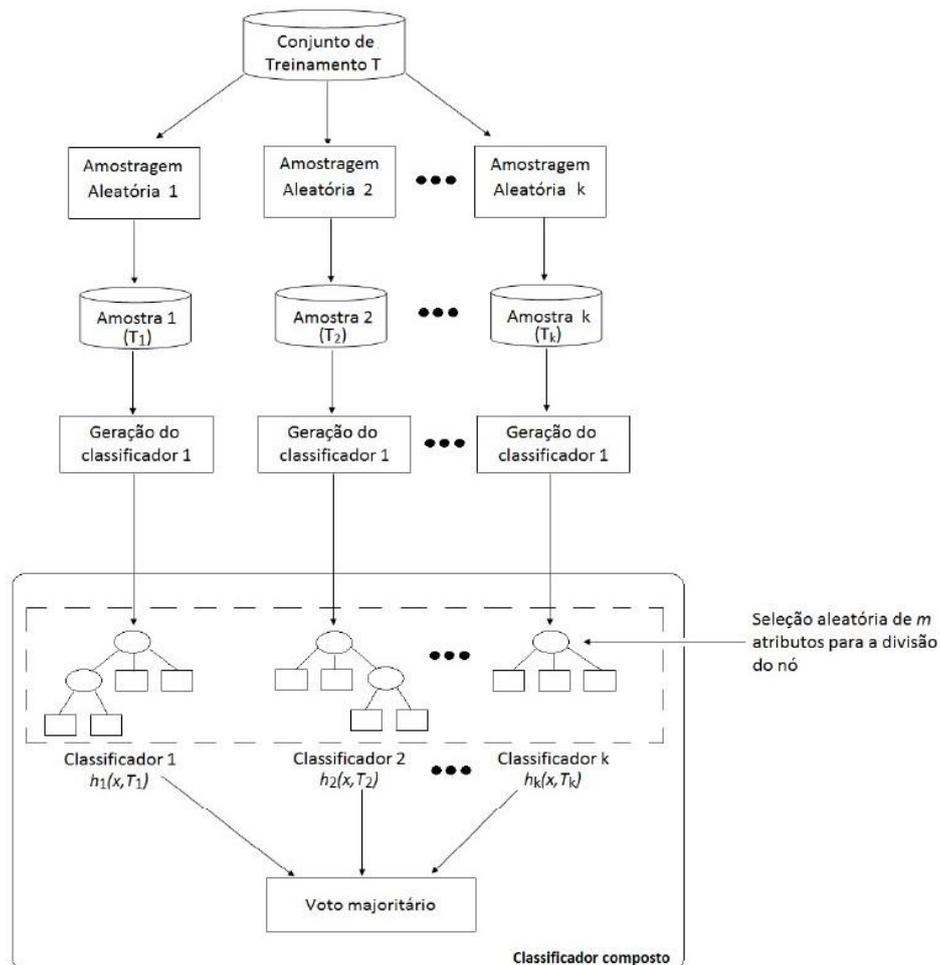
Figura 2.7 – Exemplo de árvore de decisão gerada para classificação utilizando dados de NDVI.



Fonte: Girolamo Neto (2015).

Segundo Breiman et al. (1984), o algoritmo básico de construção das árvores é usado de forma que as árvores sejam expandidas ao máximo. Um subconjunto de tamanho fixo dos atributos de entrada é selecionado aleatoriamente para a divisão de cada nó, escolhendo-se a divisão ótima dentro do subconjunto. A Figura 2.8 ilustra o funcionamento do método RF. As árvores são construídas selecionando aleatoriamente m atributos em cada nó das árvores. O melhor atributo é escolhido para dividir o nó, o valor de m é fixado para todos os nós. Esse procedimento é repetido para os demais nós da árvore, que cresce sem poda. Assim, gera-se um classificador composto por uma floresta de k árvores de classificação (OSHIRO, 2013). O resultado final do classificador é definido a partir do voto majoritário dos resultados apresentados pelas árvores de decisão.

Figura 2.8 – Funcionamento do método Random Forest.



Fonte: OSHIRO (2013).

Além de realizar a classificação, alguns algoritmos informam o grau de importância dos atributos considerados. Este é o caso do *Random Forest* do pacote Scikit-learn em Python (PEDREGOSA et al., 2011), que calcula a chamada *Feature Importance* (Importância do atributo), também conhecida como *Gini Importance* (Importância de Gini). Os atributos mais importantes da árvore tendem a estar mais profundos (mais próximos das folhas). A importância do atributo é calculada com base nessa profundidade conforme (RONAGHAN , 2018):

$$fi_i = \frac{\sum_{j:\text{node } j \text{ splits on feature } i} ni_j}{\sum_{k \in \text{all nodes}} ni_k} \quad (2.1)$$

Onde, fi_i é a importância de cada atributo e ni_j a importância do nó j dada por:

$$ni_j = w_j C_j - w_{\text{left}(j)} C_{\text{left}(j)} - w_{\text{right}(j)} C_{\text{right}(j)} \quad (2.2)$$

w_j é o número ponderado de amostras atingindo o nó j ; C_j o valor de impureza do nó j ; $\text{left}(j)$ e $\text{right}(j)$ são os nós filhos a esquerda e direita do nó j , respectivamente.

A importância do atributo geralmente é usada na sua forma normalizada, dada por:

$$\text{norm}fi_i = \frac{fi_i}{\sum_{j \in \text{all features}} fi_j} \quad (2.3)$$

A partir desta fórmula um valor de importância é atribuído a cada atributo em uma escala entre 0 e 1, onde 1 equivale ao somatório da importância de todos os atributos.

2.6 Avaliação da classificação

A validação de mapeamentos temáticos da cobertura da terra é importante para determinar o nível de confiança das análises baseadas no mapeamento (FOODY, 2002). A acurácia do mapeamento avalia a precisão e exatidão do produto de classificação. Este processo de avaliação geralmente é feito por meio de métricas como: o índice Kappa, que permite avaliar o nível de concordância entre dois conjuntos de dados; a acurácia global, que representa a relação entre a quantidade de amostras classificadas corretamente e o total de amostras rotuladas; e, as acurácias do produtor e do usuário, referentes aos erros de omissão e comissão, respectivamente. Erros de omissão ocorrem quando pixels/objetos pertencentes a uma determinada classe não são inseridos nessa categoria. Por outro lado, erros de comissão ocorrem quando pixels/objetos são

erroneamente incluídos na classe em análise. Essas estatísticas são obtidas a partir da matriz de confusão.

Estas métricas podem ser calculadas com base na comparação entre o produto de classificação obtido e um dado de referência. Os dados de referência podem ser amostras oriundas de outros mapeamentos já validados, dados coletados em campo ou até mesmo amostras definidas a partir da interpretação de imagens por especialistas experientes no tema. A plataforma Google Earth™, por exemplo, permite o acesso gratuito a imagens de alta resolução, representando uma alternativa para a interpretação visual de imagens e coleta de amostras, a baixo custo (OLOFSSON et al., 2014). Além disso, projetos tais como o Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (Mapbiomas), bem como outros realizados pela ANA, pela fundação SOS Mata Atlântica e pelo IBGE, frequentemente disponibilizam mapas de uso e cobertura da terra de diferentes regiões do Brasil. Esses mapas podem ser utilizados para validação de produtos gerados a partir da classificação de dados de SR.

3 MATERIAL E MÉTODOS

3.1 Área de Estudo

Localizada no estado de Minas Gerais, a área de estudo encontra-se principalmente na Mesorregião Metropolitana de Belo Horizonte e também na Zona da Mata Mineira, especificamente nas Microrregiões de Ouro Preto e Ponte Nova, compreendendo a bacia do Rio Doce, mais especificamente nas sub-bacias do Rio Carmo e Rio Gualaxo do Norte (IBGE, 2006).

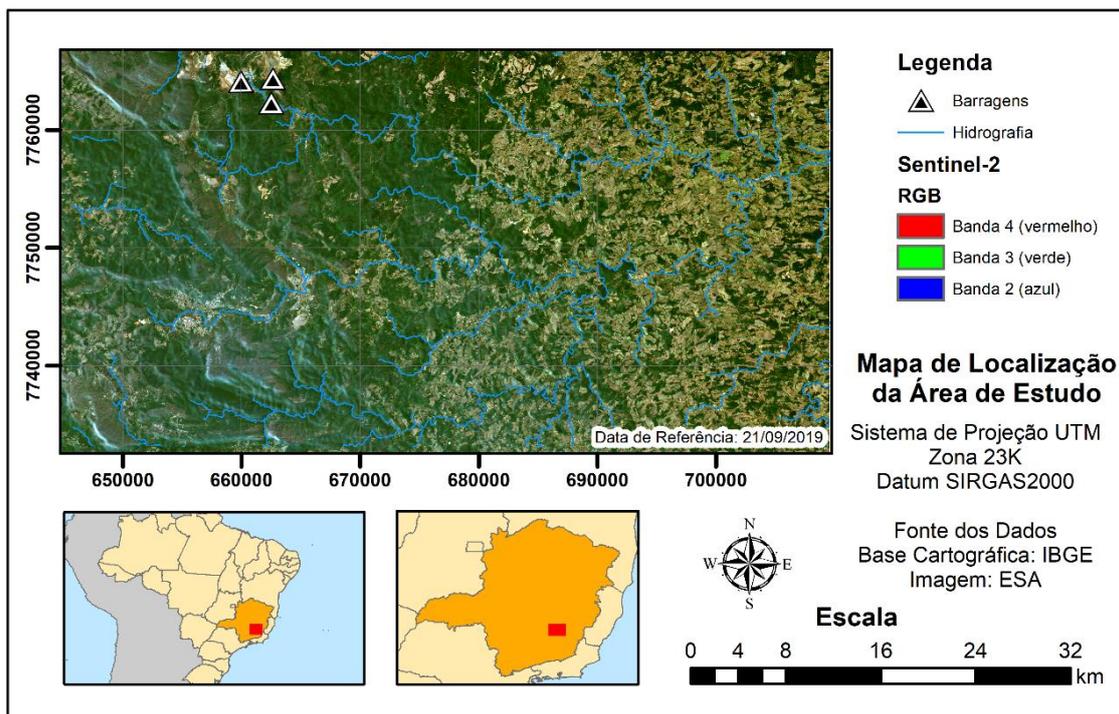
Segundo IBGE (1992), o bioma predominante nesta área é a Mata Atlântica, englobando a Floresta Estacional Semidecidual. Originalmente, a mata atlântica ocupava mais de 130.000.000 ha do território brasileiro, sendo 27.622.623 ha no estado de Minas Gerais. Esse bioma figura entre uma das regiões mais ricas e, ao mesmo tempo, mais ameaçadas do planeta. Segundo o IBAMA, em 2014, estava reduzida a 15% de sua cobertura original no Brasil. Atualmente restam apenas 12,4% da floresta (IBAMA, 2015). Em 2014, o estado de Minas Gerais tinha 2.858.654 ha de área remanescente de Mata Atlântica (INPE, 2015). Em 2015, essa área era de 2.841.728 ha (INPE, 2016), sendo reduzida para 2.836.004 ha em 2016 (INPE, 2017) e 2.828.890 ha em 2018 (INPE, 2018).

A área de estudo engloba várias Unidades de Conservação (UC), tais como o Parque Estadual do Itacolomi, o Parque Nacional da Serra da Gandarela, a Floresta Estadual do Uiamii e o Monumento Natural Estadual de Itatiaia. Essa região inclui também as Áreas de Proteção Ambiental (APAs) dos municípios de Barra Longa, Rio Gualaxo do Sul, Matinha, Carvão de Pedra; e as APAs Estaduais de Sul Região Metropolitana de Belo Horizonte, e de Cachoeira das Andorinhas. Estas áreas têm grande importância ambiental, o Parque Estadual do Itacolomi, por exemplo, abriga, aproximadamente, 11% de toda a biodiversidade conhecida para Minas Gerais, representando mais de mil espécies da fauna e da flora protegidas, sendo 29 espécies ameaçadas de extinção e 18 endêmicas (TAFURI, 2008).

A área de estudo abrange uma área de aproximadamente 2150 km² limitada pelas coordenadas geográficas 20°11'23,64" e 20°29'48,78" de latitude Sul, e 42°59'35,65" e 43°36'25,94" de longitude Oeste Figura 3.1. Esta área contém os

primeiros trechos atingidos pelo desastre de rompimento de barragem em Mariana, englobando a barragem de Fundão, o distrito de Bento Rodrigues, o Rio Gualaxo do Norte e Rio do Carmo. De acordo com a classificação climática de köppen-Geiger (RUBEL; KOTTEK, 2010), a área de estudo tem clima temperado úmido, com inverno seco e verão quente e temperaturas médias na faixa de 19,5 a 21,8° C (FARIA 2012).

Figura 3.1 – Mapa de localização da área de estudo.



Fonte: Produção do autor.

Esta área pertence ao quadrilátero ferrífero, seus solos predominantes incluem Latossolo Vermelho-Amarelo Distrófico, Cambissolo Háplico Perférico e Cambissolo Háplico Distrófico (IBGE, 2001). Essas categorias indicam solos com baixa fertilidade, com argila de alta atividade e com altos teores de óxido de ferro. Essas características ocorrem principalmente devido à formação geológica do local, composta por rochas como itabirito, dolomito, quartzito e outros (CPRM, 2014; MACHADO; SILVA, 2010; ROESER, H.; ROESER, P., 2010). Até 2013, o crescimento econômico da região estava centrado na extração mineral, sendo 31,4% relacionadas à extração de ferro e minério de ferro (ANA, 2016a). Barbosa (2004), aponta além de minério de ferro, jazidas de bauxita, ouro e manganês,

nos municípios de Mariana e Ouro Preto, que também apresentam atividades socioeconômicas voltadas essencialmente para a mineração e a metalurgia.

Além da forte extração mineral, a bacia do Rio Doce apresenta uso antrópico predominante correspondente à pastagem, ocupando 59% da sua área (ANA, 2016a). Aproximadamente 5% são ocupados por áreas agrícolas, 4% por áreas reflorestadas e 27% por vegetação nativa (ANA, 2016a). Segundo o Projeto RadamBrasil (1983), a região apresentava vegetação de Floresta estacional semidecidual. Corrêa (2006), ainda aponta a presença de campos rupestres nas áreas com afloramento rochoso e em áreas de transição para mata.

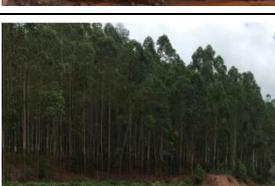
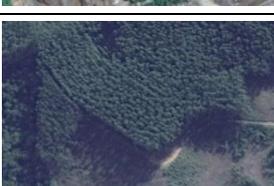
A bacia do Rio do Carmo possui área de drenagem de 227.795 ha (PIRH, 2010), e ocupa principalmente o território dos municípios mineiros Ouro Preto, Mariana, Barra Longa, Acaiaca, Diogo Vasconcelos e uma parte de Ponte Nova. Segundo o relatório da Empresa de Assistência Técnica e Extensão Rural-EMATER (2018), o conjunto de sub-bacias do alto e médio rio do Carmo, apresentou vegetação nativa em 53,58%, pastagem em 27,97%, silvicultura em 0,88% (plantios de eucalipto), área agrícola em 0,02% (plantio de cana de açúcar), solo exposto em 0,32%, afloramento de rocha em 11,92%, área urbana em 4,98% e corpos de água em 0,33% da área em estudo. Já o conjunto de sub-bacias do baixo trecho do rio do Carmo, apresentou vegetação nativa em 36,06%, pastagem em 57,21%, silvicultura em 1,39% (predomina o plantio de eucalipto), área agrícola em 1,13%, solo exposto em 2,90%, comunidade rural em 0,37% e corpos de água em 0,94% da área estudada (EMATER, 2017a).

No relatório da bacia hidrográfica do rio Gualaxo do Norte, que compreende aos municípios de Ouro Preto (parte nordeste), Mariana (parte norte) e Barra Longa (parte noroeste), a região apresentou vegetação nativa em 50,91%, pastagem em 29,80%, silvicultura em 6,44% (plantios de eucalipto), área agrícola em 0,17%, solo exposto em 1,27%, afloramento de rocha em 4,64%, mineração em 3,90%, área diretamente impactada em 1,78%, área rural em 0,70% e corpos de água em 0,39% da área da pesquisa (EMATER, 2017b).

A Tabela 3.1 mostra algumas classes de uso e cobertura da terra, caracterizadas pela Empresa de Assistência Técnica e Extensão Rural

(EMATER) na bacia, através de imagens orbitais fornecidos pela Google/Maxar Technologies, na escala 1:1.000, e fotos em campo retiradas dos relatórios da Operação Watu (SISEMA, 2016, 2020).

Tabela 3.1 – Uso e cobertura da terra na bacia do rio do Carmo.

Classe	Foto em campo	Imagem orbital de alta resolução espacial
Área Urbana (Barra Longa)		
Corpos d'água (Rios Carmo e Gualaxo do Norte (à esquerda).		
Pastagem		
Solo exposto		
Rocha		
Eucalipto		
Floresta		

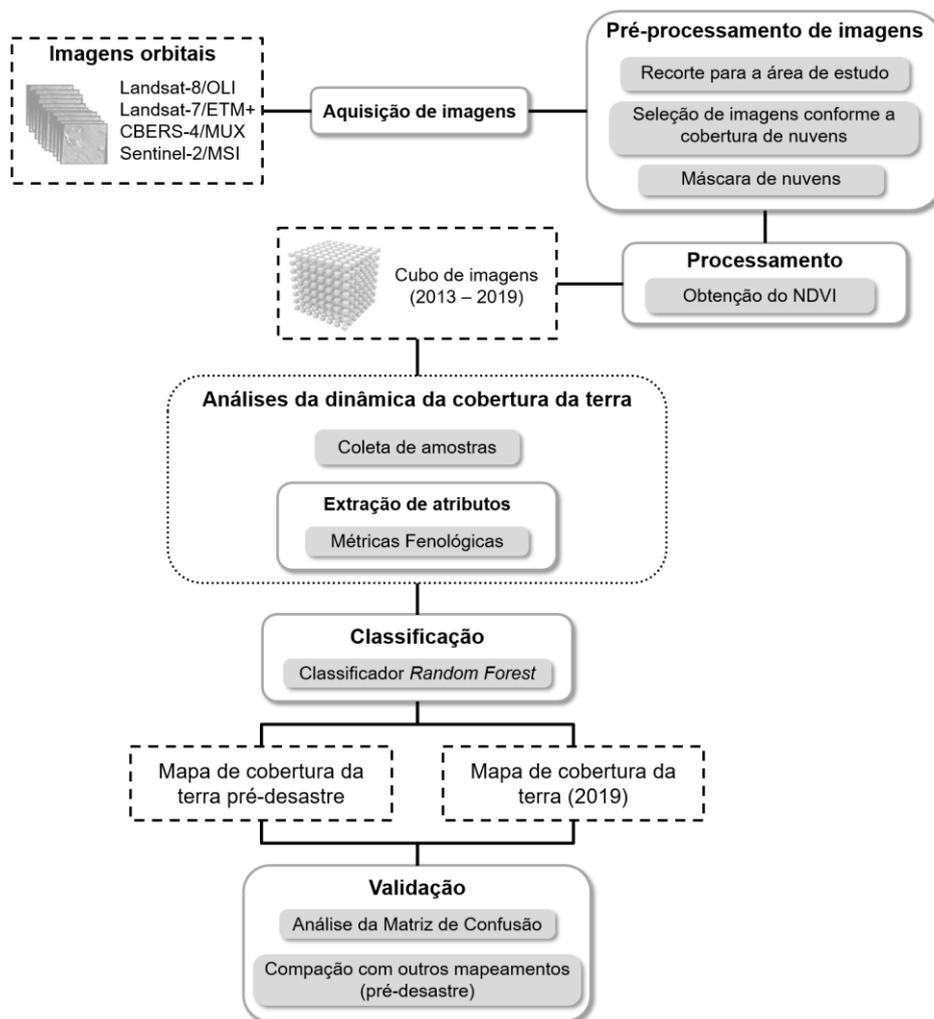
Fonte: Produção do Autor.

Já nos municípios Barra Longa, Acaiaca e Diogo de Vasconcelos, as atividades econômicas predominantes são a pecuária, com a criação de gado bovino leiteiro e produção agrícola de milho, café, arroz, feijão e fumo, todos produzidos em pequena escala. No município de Ponte Nova prevalece a produção agrícola de cana-de-açúcar, onde a principal atividade econômica são as usinas açucareiras, com produção de açúcar, álcool e aguardente (BARBOSA, 2004).

3.2 Metodologia

A Figura 3.2 apresenta a metodologia proposta neste trabalho. Ela ilustra as principais fases de processamento que foram executadas para a geração do cubo de imagens de NDVI, da análise da dinâmica da cobertura da terra, da classificação pré-desastre e pós-desastre, e da validação da classificação.

Figura 3.2 – Fluxograma das etapas da metodologia.



Fonte: Produção do autor.

3.2.1 Aquisição e pré-processamento de dados

Este trabalho combinou imagens orbitais das coleções Landsat-8/OLI, Landsat-7/ETM+, Sentinel-2/MSI e CBERS-4/MUX, entre abril de 2013 e setembro de 2019, para gerar as séries temporais, levando em conta a cobertura de nuvens da área. A Tabela 3.2 apresenta as principais características dos sensores utilizados na pesquisa.

Tabela 3.2 – Principais características dos sensores utilizados.

Características	Landsat-8/OLI	Landsat-7/ETM+	CBERS-4/MUX	Sentinel-2/MSI
Resolução espacial	30 metros	30 metros	20 metros	10 metros
Resolução temporal	16 dias	16 dias	26 dias	5 dias
Resolução radiométrica	16 bits	8 bits	8 bits	12 bits
Resolução espectral (μm)	B4: 0,636-0,673 B5: 0,851-0,879	B3: 0,63-0,69 B4: 0,76-0,90	B07: 0,63-0,69 B08: 0,77-0,89	B4: 0,664-A/0,665-B (10 m) B8: 0,835-A/0,833-B (10 m)

Fonte: Produção do autor.

As imagens Landsat foram adquiridas por meio da plataforma *Google Earth Engine* (GEE) (GOOGLE, 2015), que disponibiliza em seu catálogo os produtos ortorretificados de reflectância de superfície *USGS Landsat 8 Surface Reflectance* e *USGS Landsat 7 Surface Reflectance*. A correção atmosférica dos dados foi realizada para o Landsat-8 e Landsat-7 pelos algoritmos LaSRC (*Landsat 8 Surface Reflectance Code*) e LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*), respectivamente (EARTH ENGINE DATA CATALOG, 2018). Além disso, foram adquiridas também bandas com máscara de nuvens (QA band) produzidas pelo algoritmo *Cloud Function MaskCFMask* (EARTH ENGINE DATA CATALOG, 2018).

As imagens dos satélites CBERS-4 e Sentinel-2, em valores de reflectância de superfície, não estavam disponíveis na plataforma GEE. As imagens de reflectância do CBERS-4 e Sentinel-2, e a máscara de nuvens foram disponibilizadas pelo INPE. A correção atmosférica foi realizada no *software* MS³, que utiliza dados auxiliares MODIS MOD/MYD 09 CMA e CMG e o modelo de transferência radiativa 6S (Silva e Andrade, 2013). As imagens Sentinel-2

foram processadas no *software* Sen2Cor para obtenção do produto Level-2A, referente à reflectância de superfície, e da banda *Classification Mask*, utilizada neste trabalho como máscara de nuvens. Essa banda apresenta, dentre outras informações, a probabilidade (e.g., alta, média) de ocorrência de nuvens e sombras de nuvens (ESA, 2000-2020).

Para a seleção das imagens, foi definida uma cobertura de nuvens máxima de 20% na área de estudo. Nesta etapa, a taxa de cobertura de nuvens na área de estudo foi estimada com base nas bandas de máscara de nuvens. Para as imagens Landsat-7 e Landsat-8, este procedimento foi realizado no GEE, enquanto que para as imagens CBERS-4 e Sentinel-2 a estimativa foi feita na linguagem Python. As bandas referentes à máscara de nuvens também foram utilizadas para eliminar os demais pixels contaminados com nuvens ou sombras de nuvens.

Após esta etapa, os valores de NDVI para cada cena foram calculados, conforme descrito na Seção 2.2. Este processamento, bem como os seguintes, foi executado em linguagem Python. As imagens foram recortadas com base no polígono da área de estudo e, posteriormente, convertidas para um mesmo sistema de referência. Em seguida, um processo de filtragem dos dados foi realizado para identificar datas para as quais existissem mais de uma imagem. Para esses casos, apenas a imagem de melhor resolução espacial foi mantida para evitar a redundância dos dados. Desta forma, um cubo de dados foi gerado contendo imagens de 2013 a 2019 referentes à área de estudo. Para satélites que têm mais de uma banda referentes aos intervalos espectrais do infravermelho e vermelho (caso do Sentinel-2), optou-se pelas bandas com maior proximidade espectral dos demais satélites. As bandas consideradas no cálculo do NDVI são apresentadas na Tabela 3.2.

A série temporal considerou a grade de pixels das imagens Landsat como base para a integração dos dados provenientes de outros satélites. No trabalho não foram aplicadas formas de harmonização radiométrica das imagens, normalização, ou mesmo de reamostragem, a opção foi por tentar extrair informações destes dados com o mínimo de processamento. Esta alternativa é interessante devido ao tempo e alto custo computacional necessários para

aplicação destes tratamentos em grandes conjuntos de dados. Independente da resolução espacial da imagem, para cada coordenada central de pixel Landsat, obteve-se um valor de NDVI por imagem da série. Desta forma, os dados das diferentes coleções foram integrados na série temporal.

Nesse trabalho, dados faltantes devido à presença de nuvens ou sombras de nuvens, ou no caso das imagens Landsat-7, às falhas do SLC (*Scan Line Corrector*), foram preenchidos utilizando a média de observações adjacentes no tempo. Em outras palavras, cada valor faltante foi substituído pela média entre as observações obtidas, para aquele mesmo ponto, na data anterior e posterior à data sem observação. Esse procedimento é ilustrado na Figura 3.3. Observe que dados faltantes referentes à data inicial ou final da série temporal são preenchidos utilizando a observação adjacente no tempo. Este processo foi executado pelo fato de softwares e pacotes para classificação terem dificuldade de lidar com essas lacunas.

Figura 3.3 – Preenchimento dos dados faltantes.

Pixel	Data (Imagem)							
	20130506	20130514	20130701	20130802	20130810	...	20190920	20190921
0	0,2		0,4		0,6	...	0,8	0,9
1		0,2			0,6	...	0,8	
2	0,1				0,3	...	0,4	0,3
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮	⋮

PREENCHIMENTO DOS DADOS FALTANTES

↓

Pixel	Data (Imagem)							
	20130506	20130514	20130701	20130802	20130810	...	20190920	20190921
0	0,2	0,3	0,4	0,5	0,6	...	0,8	0,9
1	0,2	0,2	0,4	0,4	0,6	...	0,8	0,8
2	0,1	0,2	0,2	0,2	0,3	...	0,4	0,3
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮	⋮

As datas estão escritas na forma 'YYYYMMDD', onde os quatro primeiros dígitos indicam o ano, o quinto e sexto dígito indicam o mês e, os últimos dois dígitos representam o dia. As células em cinza indicam as observações faltantes que foram preenchidas pela média dos valores adquiridos em datas adjacentes (células à esquerda e à direita).

Fonte: Produção do autor.

3.2.2 Extração de métricas

A série temporal adquirida foi empregada para criação de dois mapas de cobertura da terra, considerando o período pré-desastre e pós-desastre gerados usando o classificador Random Forest. No classificador foram usados como dados de entrada as séries temporais de NDVI e algumas métricas. Ao todo, 16 métricas foram extraídas a partir das séries temporais de NDVI e consideradas na classificação. Nesse caso, a série temporal original foi utilizada sem o preenchimento dos dados faltantes, extraindo as métricas de valores mais próximos dos originais. Usando o pacote *stmetrics* em Python (SOARES, 2020 no prelo), foram extraídas as seguintes métricas: amplitude, média, valor máximo, valor mínimo, desvio padrão e soma, first slope, ecentricidade, raio de rotação, balanço polar, área, ângulo, área por quadrante. A Tabela 3.3 apresenta uma breve descrição das métricas fenológicas utilizadas.

Tabela 3.3 – Métricas extraídas a partir de séries temporais.

Nome	Tipo	Descrição
Amplitude	Básica	Diferença entre os valores de máximo e mínimo da série temporal.
Média	Básica	Valor médio da série temporal.
Desvio-padrão	Básica	Desvio-padrão da série temporal.
Máximo	Básica	Valor máximo da série temporal, sensível a ruído.
Mínimo	Básica	Valor mínimo da série temporal.
Soma	Básica	A soma dos valores da série temporal.
First slope	Básica	Indica quando a série temporal apresenta mudanças abruptas.
Ecentricidade	Polar	Valores próximos a 0 quando se aproxima de um círculo e 1 se for similar a uma linha.
Raio de Rotação	Polar	Distância média entre os pontos dentro da forma e seu centróide.
Balanço polar	Polar	Desvio-padrão das áreas por estação, considerando 4 estações.
Área	Polar	Área da forma fechada. Valores altos indicam séries de valores altos.
Ângulo	Polar	O ângulo principal da forma fechada criada na visão polar.
Área por quadrante	Polar	Área parcial da forma fechada para cada quadrante, 1, 2, 3, 4.

Fonte: Adaptada de Soares et al. (2020, no prelo).

3.2.3 Classificação utilizando o Random Forest

Neste trabalho foram gerados dois mapas de cobertura da terra para a área de estudo, correspondentes aos cenários, pré-desastre (2015) e pós-desastre (2019), ambos criados com base na classificação de série temporal. O mapa de cobertura da terra pré-desastre foi gerado com base na série temporal constituída pelas imagens datadas entre abril de 2013 e 05 de novembro de 2015. Por outro lado, o mapa pós-desastre foi gerado com as imagens adquiridas a partir de 05 de novembro de 2016 até setembro de 2019, ou seja, iniciando-se um ano após o desastre. Este período foi definido para amenizar confusões causadas devido a presença de lama. A Tabela 3.4 mostra a quantidade de imagens de cada sensor que foi utilizada nas classificações.

Tabela 3.4 – Quantidade de imagens por classificação.

Classificação	Landsat-8/OLI	Landsat-7/ETM+	CBERS-4/MUX	Sentinel-2/MSI	Total
Pré-desastre	18	24	2	-	44
Pós-desastre	20	21	6	45	92

Fonte: Produção do autor.

As amostras de treinamento e avaliação foram coletadas por meio da interpretação visual de imagens de alta resolução disponíveis no Google Earth™. Na coleta, foram adquiridas amostras de 7 classes: afloramento rochoso, mineração, água/rejeito, área construída, gramíneas e herbáceas, formação florestal e formação savânica. A coleta das amostras foi feita observando a estabilidade da amostra no tempo, ou seja, optou-se por áreas que não apresentassem uma mudança de classe durante o período considerado na classificação. Embora as classes água e rejeito tivessem respostas espectrais distintas, elas apresentaram bastante confusão entre si nos testes de classificação. Por este motivo, estas classes foram agrupadas, embora as amostras de cada classe terem sido coletada separadamente, garantindo um número de amostras representativo.

As amostras coletadas foram divididas aleatoriamente em dois conjuntos: 50% das amostras para o treinamento do classificador e 50% das amostras para

medidas de acurácia das classificações realizadas. Além disso, no caso das amostras de treinamento, para cada coordenada de amostra coletada por interpretação visual, foi coletada uma região de 3x3 pixels na série temporal correspondente. Esta coleta por regiões tem o objetivo de aumentar a variabilidade das amostras de treinamento para cada classe. Assim para cada amostra obtida por interpretação visual, 9 perfis de série temporal são gerados, para treinamento do modelo de classificação, um perfil temporal por pixel da amostra. O número de amostras definido para cada classe, em cada uma das classificações, é apresentado na Tabela 3.5.

Tabela 3.5 – Quantidade de amostras por classificação.

Classes	Número de amostras			
	Pré-desastre		Pós-desastre	
	Treinamento	Teste	Treinamento	Teste
Afloramento Rochoso	99 (11 x 9)	11	99 (11 x 9)	11
Água/rejeito	63 (7 x 9)	7	63 (7 x 9)	7
Mineração	36 (4 x 9)	4	45 (5 x 9)	5
Área Construída	54 (6 x 9)	6	54 (6 x 9)	6
Formação Florestal	108 (12 x 9)	12	108 (12 x 9)	12
Formação Savânica	45 (5 x 9)	5	45 (5 x 9)	5
Gramíneas e herbáceas	72 (8 x 9)	8	81 (9 x 9)	9
Total de amostras	477	53	495	55

Fonte: Produção do autor.

Para analisar a contribuição das métricas fenológicas na geração de ambos os mapeamentos, dois testes de classificação foram realizados: i) adotando apenas dados da série temporal de NDVI; ii) utilizando as métricas fenológicas como atributos para a classificação, além dos dados da série temporal. As classificações foram realizadas utilizando o classificador *Random Forest* do pacote Scikit-learn (PEDREGOSA et al., 2011). Os resultados das classificações foram analisados utilizando o conjunto de amostras para teste por meio da matriz de confusão e valores de exatidão do produtor e do usuário e acurácia global.

3.2.4 Pós-processamento

Para a geração dos mapas de cobertura da terra pré e pós-desastre, as classificações obtidas com as melhores acurácias foram pós-processadas, adotando-se um filtro de moda (3x3) para remoção de ruídos de classificação. Além disso, máscaras das classes agricultura e água foram usadas nos mapeamentos, para uma melhor representação dessas classes. A máscara de água, extraída com base em modelos SRTM conforme ROSIM et al. (2013), foi utilizada devido ao fato de a resolução espacial (30 m) não ter permitido uma identificação adequada dos cursos hídricos da região. A máscara de agricultura foi criada por meio de interpretação visual com o auxílio de imagens Google Earth™ e algumas cenas *RapidEye* do banco de dados do INPE. As áreas de agricultura familiar, possuindo talhões reduzidos de culturas diversificadas, não permitiram sua identificação por meio da classificação automática.

3.2.5 Validação do mapa de cobertura da terra pré-desastre

A validação do mapa de cobertura da terra pré-desastre foi feita pela comparação deste a outros mapas de cobertura da terra que fazem uso de diferentes metodologias de mapeamento. Neste caso, foi feito um levantamento dos mapeamentos já existentes para a área de estudo entre 2013 e 2015. Sete mapas foram utilizados para criar o mapa de referência: os mapas do MAPBIOMAS, referente aos anos de 2013, 2014 e 2015 (PROJETO MAPBIOMAS, 2019); os mapas da SOS Mata Atlântica para o mesmo período (INPE, 2015, 2016, 2017); e um mapeamento de uso e cobertura da bacia do Rio Doce realizado pela ANA por interpretação visual de imagens entre 2013 e 2014 (ANA, 2016c). No apêndice A estão ilustrados alguns destes mapeamentos para a área de estudo.

A partir destes mapas foi criado um mapa de referência usado na validação das classificações realizadas neste trabalho. O primeiro passo para criar o mapa de referência a partir dos mapas MapBiomias, SOS Mata Atlântica e ANA foi a compatibilização das legendas destes mapas e a legenda do mapeamento desenvolvido neste trabalho. Este processo é ilustrado na Tabela 3.6. A combinação entre estes mapeamentos permitiu uma abrangência de toda a área

de estudo e todas as classes de mapeamento de interesse deste trabalho. Para manter apenas áreas com classes mais estáveis no tempo para o mapa de referência, os mapas do Mapbiomas foram combinados em um mapa pela interseção entre os mapas referentes a 2013, 2014 e 2015. Neste mapa foram mantidas apenas as áreas cujas classes se mantiveram a mesma entre 2013 e 2015. O mesmo foi feito para os mapas da SOS Mata Atlântica.

Para aumentar a confiabilidade do mapa de referência, as áreas de discordância entre os mapeamentos foram eliminadas. As áreas que apresentavam discordância entre a interseção entre os mapas do MapBiomas, a interseção entre os mapeamentos da SOS Mata Atlântica e o mapa da ANA foram removidas. Os mapas do MapBiomas são os únicos que abrangem toda a área de estudo, e por este motivo as áreas que não apresentavam informações nos demais mapeamentos, para permitir a comparação, permaneceram com a informação do MapBiomas.

Tabela 3.6 – Compatibilização das classes dos mapeamentos.

Pré-desastre	MapBiomas	SOS Mata Atlântica	ANA
Afloramento Rochoso	Afloramento Rochoso	Afloramento Rochoso	-
Água/rejeito	Água+Rios,Lagos,Oceanos	Água	-
Mineração	Mineração	Mineração	-
Área Construída	Infraestrutura Urbana	Área Urbana	Área Urbana
Formação Florestal	Formação Florestal + Floresta Plantada	Vegetação Nativa + Reflorestamento	Mata
Formação Savânica	Formação Savânica	-	-
Agricultura + Gramíneas e herbáceas	Agricultura e Pastagem	Pastagem	-

Fonte: Produção do autor.

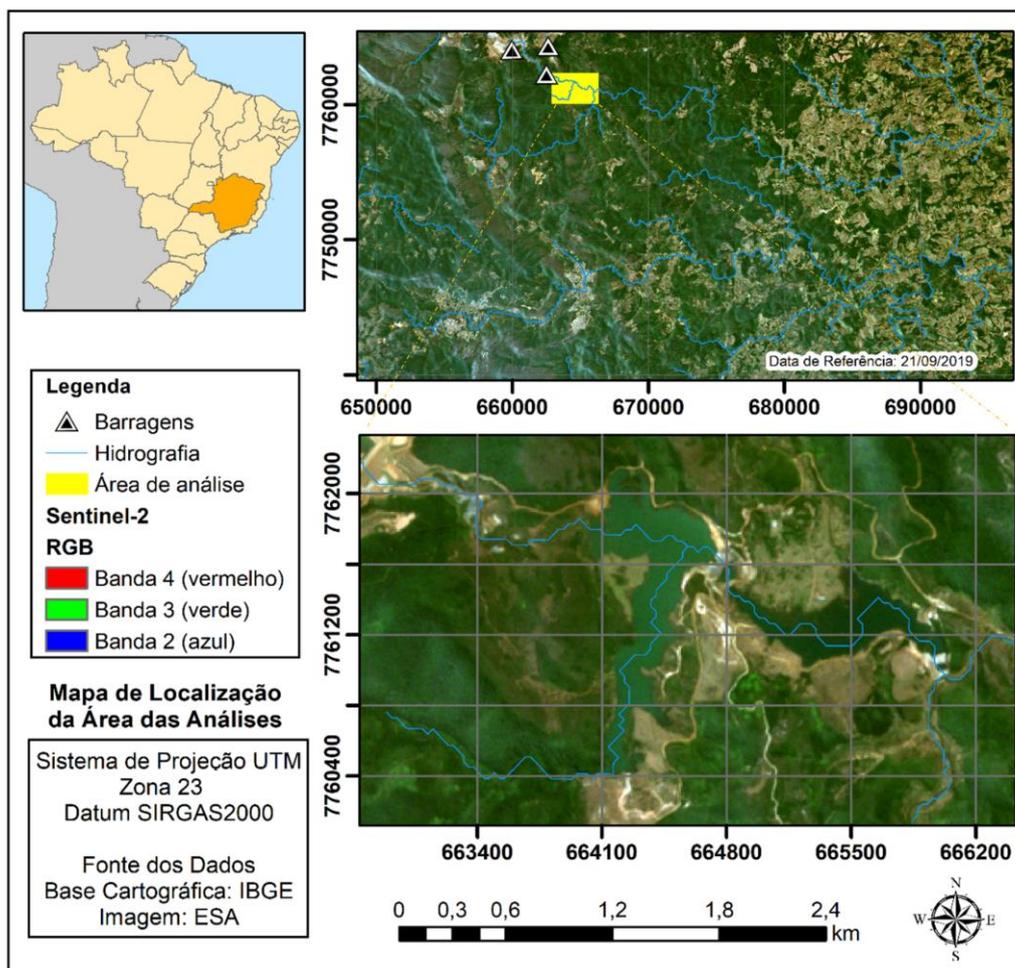
Finalmente, o mapa de referência resultante da combinação destes mapeamentos foi utilizado para a geração de matriz de confusão e cálculos de exatidão do produtor, do usuário e acurácia global. Todos os pixels preenchidos do mapa de referência foram utilizados para esta comparação, sendo os resultados obtidos referentes a concordância entre os mapeamentos.

3.2.6 Análises das mudanças da cobertura da terra

Na busca por compreender melhor as mudanças associadas ao desastre de Mariana, foram efetuadas uma série de análises usando tanto as classificações quanto a própria série temporal de NDVI. Para a identificação das mudanças na área de estudo de forma ampla foi realizada uma subtração entre os resultados dos mapas pré e pós-desastre. Identificando áreas que sofreram alteração neste período de tempo.

As séries temporais foram analisadas para observar a dinâmica das mudanças na cobertura da terra no período de abril 2013 a setembro de 2019. Para fazer análises mais específicas de mudanças associadas ao desastre de Mariana foi definida uma área mais restrita dentro da área de estudo (Figura 3.4). Na área de estudo existem diferentes alvos, e existe também uma predominância de áreas não afetadas pelo desastre.

Figura 3.4 – Mapa de localização da área de estudo.



Fonte: Produção do autor.

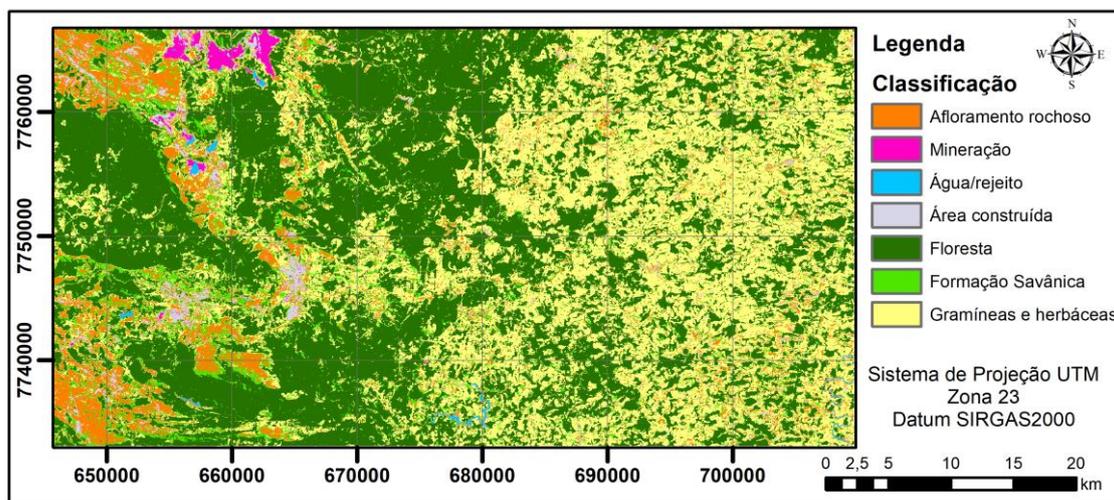
Nesta área de análise foram coletadas cerca de 50 amostras pontuais, sendo observadas regiões de 3x3 pixels referentes às classes de cobertura da terra observadas em áreas atingidas pelo desastre. Estas amostras foram utilizadas para identificar alguns padrões de mudanças associados ao evento. As amostras foram definidas com o auxílio do Google Earth™ para garantir que as regiões de coleta de amostras estivessem dentro das áreas afetadas pelo desastre.

Algumas destas amostras foram usadas para a identificação das áreas atingidas pelo desastre de Mariana, como áreas degradadas e de áreas que foram alagadas no processo de construção de diques de contenção, após o desastre. Este processo permitiu a identificação da transição das classes no período entre o mapeamento pré e pós-desastre, e foi feito utilizando as séries temporais e o classificador *Random Forest*.

Posteriormente, para esta área de análise, o resultado anterior e as classificações pré e pós-desastre foram analisadas na busca por identificar algumas das transições da cobertura da terra ocorridas em decorrência do desastre de Mariana. Por fim estas transições foram quantificadas e apresentadas na forma de Diagrama de Sankey.

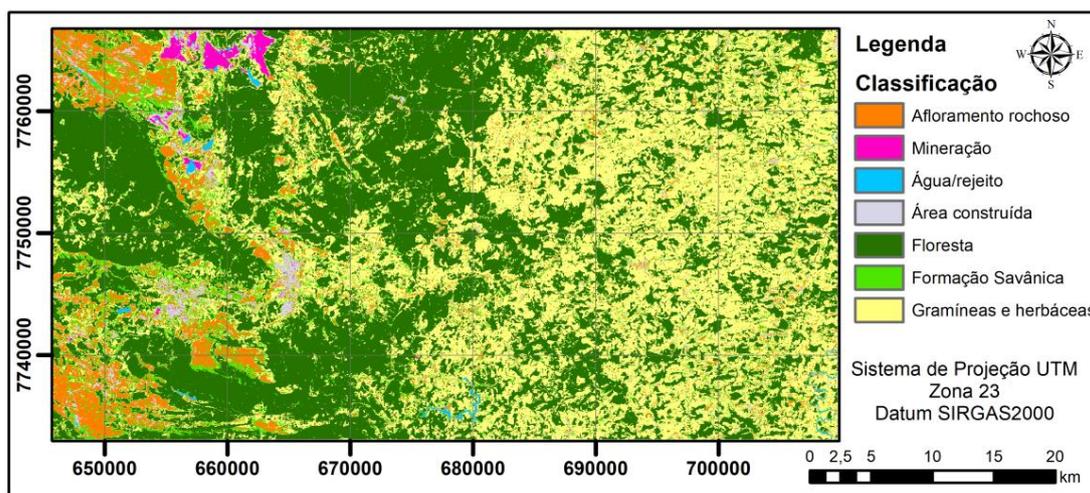
NDVI e a Figura 4.3 apresenta o resultado para a série temporal de NDVI associada as métricas fenológicas.

Figura 4.2 – Classificação das séries temporais de NDVI pré-desastre.



Fonte: Produção do autor.

Figura 4.3 – Classificação das séries temporais de NDVI e métricas fenológicas pré-desastre.



Fonte: Produção do autor.

A Tabela 4.1 apresenta a matriz de confusão referente a classificação dos dados da série temporal de NDVI. Por outro lado, a Tabela 4.2 apresenta os resultados obtidos ao se considerar tanto a série temporal de dados NDVI quanto as métricas fenológicas durante a classificação.

Tabela 4.1 – Matriz de confusão da classificação pré-desastre das séries temporais de NDVI.

	Classes	Real (Pixels)						
		Afloramento Rochoso	Mineração	Água/rejeito	Área Construída	Formação Florestal	Formação Savânica	Gramíneas e herbáceas
Predição (Pixels)	Afloramento Rochoso	8	0	0	0	0	3	1
	Mineração	0	2	0	2	0	0	0
	Água/rejeito	0	0	7	0	0	0	0
	Área Construída	1	2	0	4	0	0	0
	Formação Florestal	0	0	0	0	12	0	1
	Formação Savânica	2	0	0	0	0	2	1
	Gramíneas e herbáceas	0	0	0	0	0	0	5
Ac. Produtor (%)		72,73	50,00	100,00	66,67	100,00	40,00	62,50
Ac. Usuário (%)		66,67	50,00	100,00	57,14	92,31	40,00	100,00
Ac. Global (%)		75,47						

Fonte: Produção do autor.

Tabela 4.2 – Matriz de confusão referente à classificação pré-desastre das séries temporais de dados NDVI e métricas fenológicas.

	Classes	Real (Pixels)						
		Afloramento Rochoso	Mineração	Água/rejeito	Área Construída	Formação Florestal	Formação Savânica	Gramíneas e herbáceas
Predição (Pixels)	Afloramento Rochoso	8	0	0	0	0	2	0
	Mineração	0	2	0	2	0	0	0
	Água/rejeito	0	0	7	0	0	0	0
	Área Construída	1	2	0	4	0	0	0
	Formação Florestal	0	0	0	0	12	0	1
	Formação Savânica	2	0	0	0	0	3	0
	Gramíneas e herbáceas	0	0	0	0	0	0	7
Ac. Produtor (%)		72,73	50,00	100,00	66,67	100,00	60,00	87,50
Ac. Usuário (%)		80,00	50,00	100,00	57,14	92,31	60,00	100,00
Ac. Global (%)		81,13						

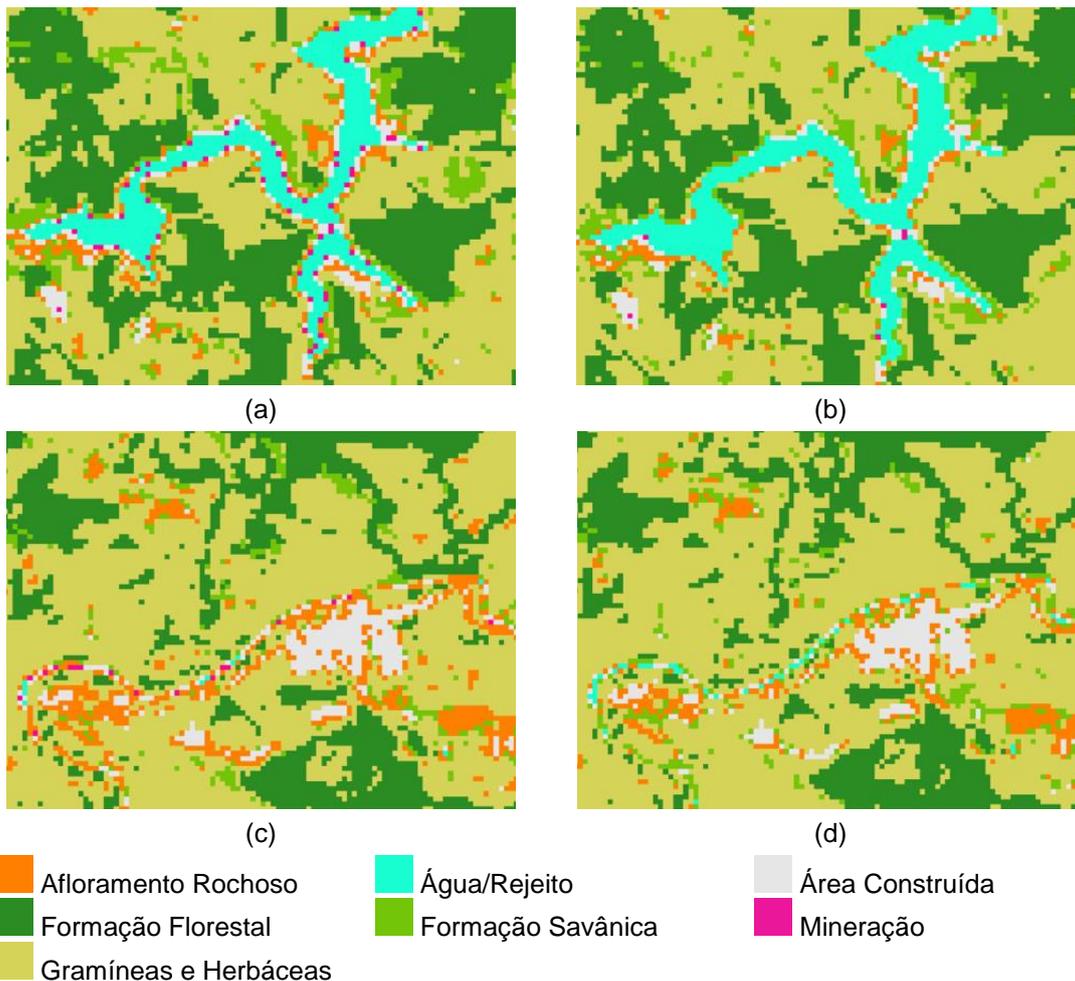
Fonte: Produção do autor.

Ambas as classificações apresentaram confusão entre as classes afloramento rochoso e formação savânica, possivelmente pelo fato da classe formação savânica, dentro da área de estudo, se apresentar como uma formação de transição entre as áreas de afloramento rochoso e demais formas de vegetação. Deve se destacar, que áreas estáveis no tempo com a presença da classe formação savânica são restritas na área de estudo, o que limitou o número de amostras, de treinamento e de teste para esta classe. A classe afloramento rochoso também apresentou confusão com a classe gramíneas e herbáceas, provavelmente por este tipo de vegetação poder ser encontrado nestas áreas, principalmente durante a estação chuvosa.

Já a classe área construída apresentou, em ambas classificações, confusão com as classes afloramento rochoso e mineração. Na região do estudo há a predominância de áreas urbanas de pequeno e médio porte, considerando-se a resolução espacial de 30 m a mistura espectral presente no pixel favorece este tipo de confusão em classificações semi-automáticas. A classe gramíneas e herbáceas apresentou confusão com as demais classes de vegetação. Porém, esta confusão é minimizada quando as métricas fenológicas foram utilizadas na classificação.

Por outro lado, a classe água/rejeito apresentou 100% de acurácia de acordo com a matriz de confusão. Porém, este valor elevado é influenciado pelo número restrito de amostras. Pode-se observar, por análise visual, que a classificação que usou as métricas fenológicas apresentou melhor resultado. A redução na confusão entre as classes mineração, afloramento rochoso e classe água, permitiu uma melhor classificação das classes mineração e afloramento rochoso, além de uma melhor definição dos cursos hídricos. A Figura 4.4 mostra resultados da classificação de duas regiões a partir da série temporal de NDVI e da classificação utilizando os dados de NDVI e as métricas fenológicas.

Figura 4.4 – Comparação das classificações pré-desastre para duas regiões.



Os resultados (a) e (c) foram obtidos a partir da classificação que considera apenas a série temporal de NDVI; enquanto que os resultados (b) e (d) foram obtidos pela classificação que considera a série temporal de NDVI e as métricas fenológicas. Observe a melhor classificação dos cursos hídricos quando consideradas as métricas.

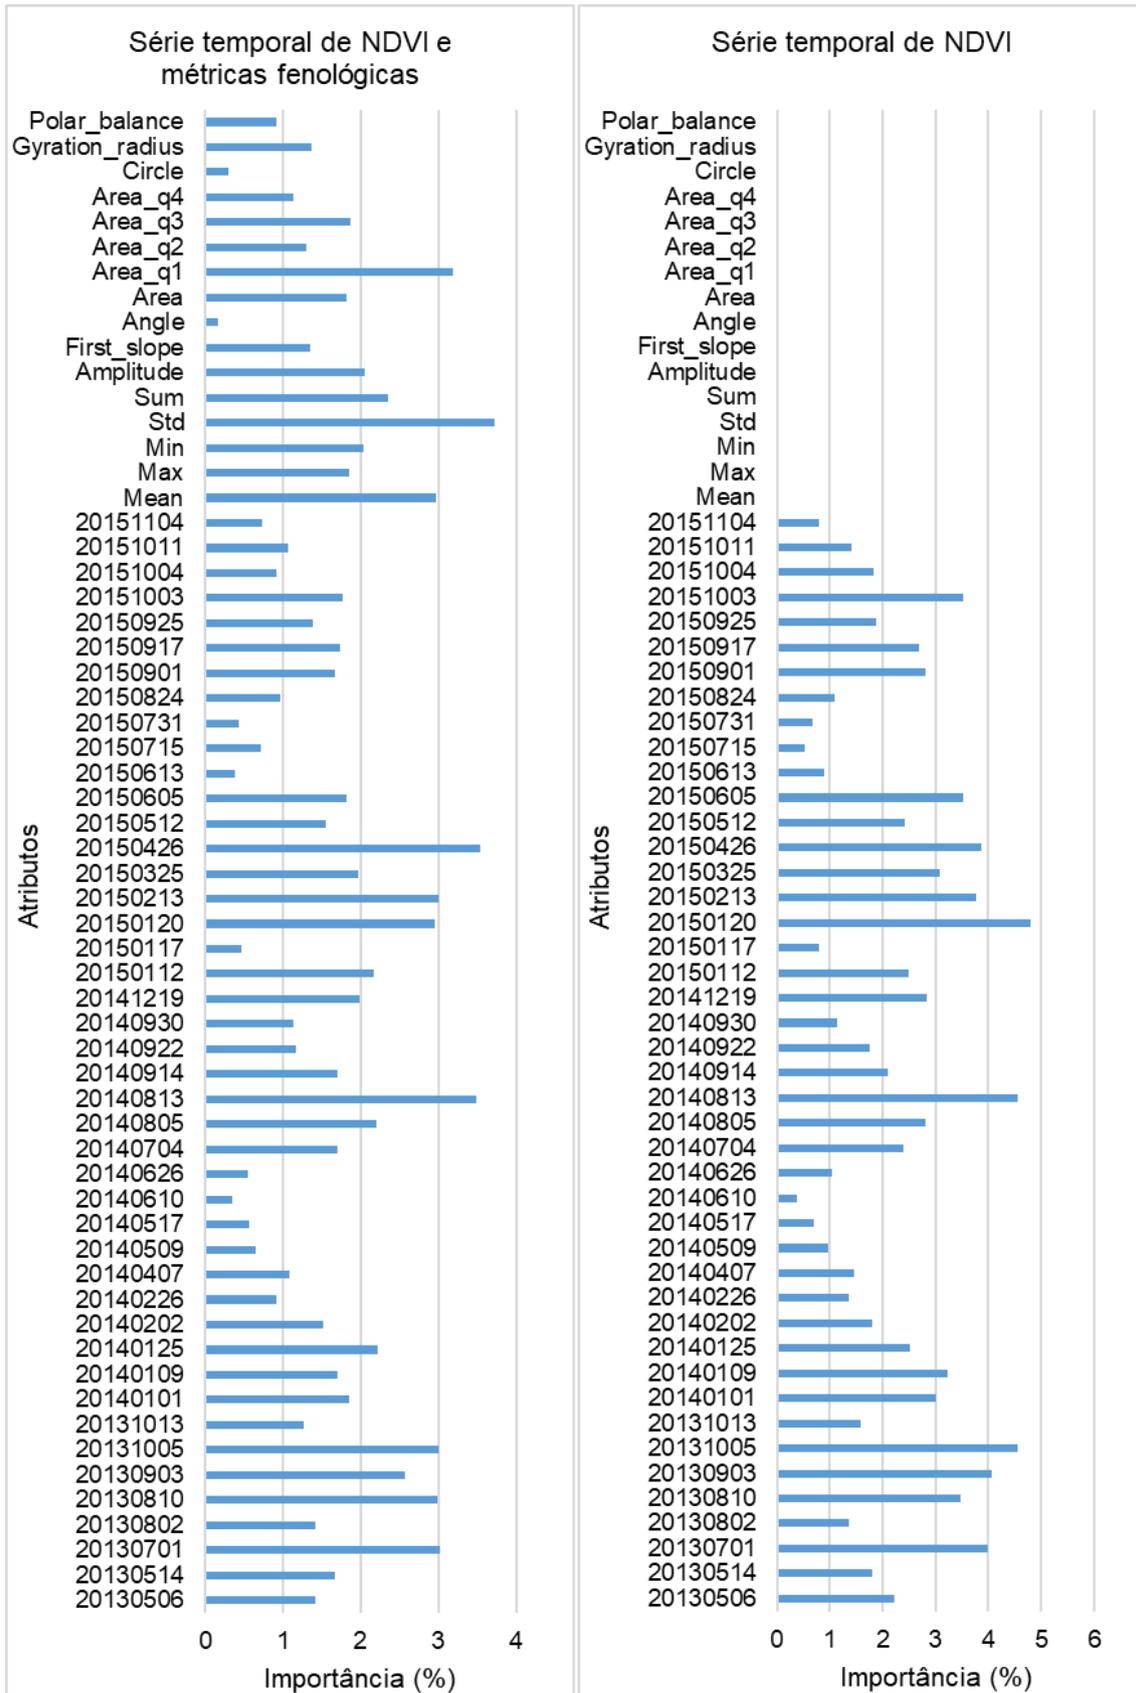
Fonte: Produção do autor.

Apesar das séries temporais serem de valores de índices de vegetação representando uma resposta fenológica da vegetação, os valores baixos dos índices de vegetação são indicativos da não presença dessa classe, permitindo classificar outros tipos de cobertura da terra. Apesar de estarem sendo chamadas de métricas fenológicas, este trabalho aplicou métricas básicas como amplitude e desvio-padrão que permitem uma melhor diferenciação entre as curvas das séries temporais no momento da classificação. Neste sentido estas métricas contribuíram para a diferenciação de classes que não apresentam uma resposta fenológica.

A utilização destas métricas também diminuiu a confusão entre outras classes. Dentre as diferenças se observou aumentos superiores a 20% nas acurácias do produtor e do usuário das classes formação savânica e gramíneas e herbáceas. A classe afloramento rochoso também apresentou aumento superior a 13% na acurácia do produtor. Os resultados das classificações mostraram um aumento superior a 5% de acurácia global ao se considerar as métricas fenológicas na classificação.

A Figura 4.5 apresenta os gráficos com a importância dos atributos de cada classificação realizada. A utilização das métricas fenológicas diminuiu a importância do NDVI de algumas imagens referentes a datas específicas na classificação. Esta diminuição da importância dos atributos referentes a uma única imagem e aumento da importância dos atributos que consideram toda a série temporal, nesse caso as métricas fenológicas, reduz a influência dos ruídos presentes nas imagens sobre a classificação. Dentre as 16 métricas utilizadas a de maior importância foi o desvio-padrão (Std), seguida pelos atributos área do primeiro quadrante (Area_q1) e média (Mean).

Figura 4.5 – Importância de cada atributo utilizado nas classificações pré-desastre.

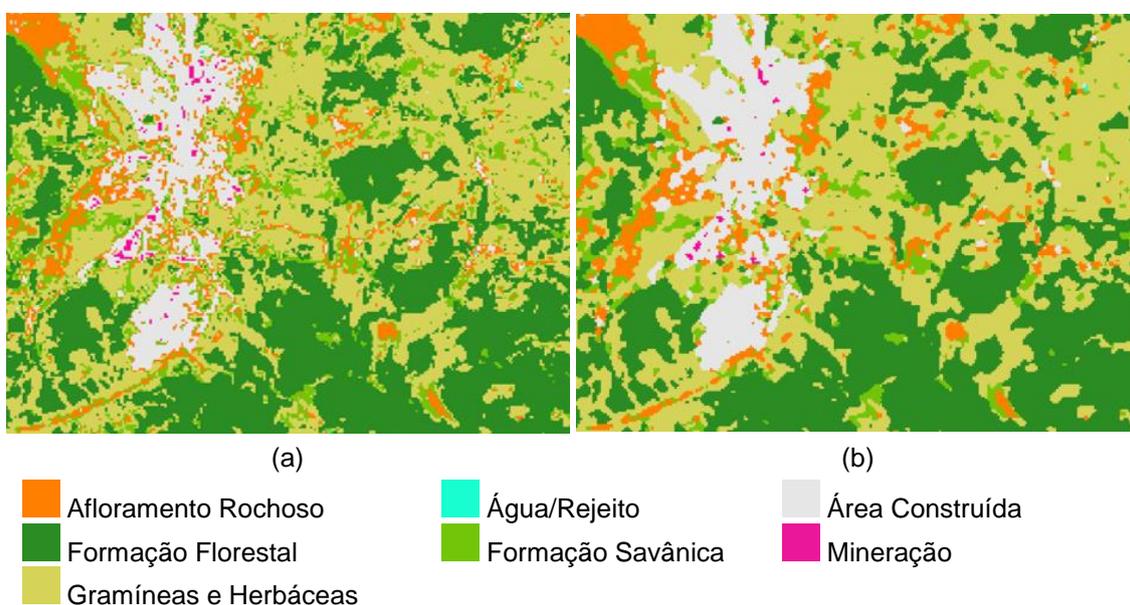


Fonte: Produção do autor.

4.2.2 Pós-processamento e validação pré-desastre

Partindo das comparações anteriores, a classificação pré-desastre das séries temporais de NDVI, usando as métricas fenológicas, apresentou um melhor resultado em relação a utilização apenas das séries temporais de NDVI. Portanto, esta classificação foi adotada para a criação do Mapa de cobertura da terra pré-desastre. Para minimizar a presença de ruídos do tipo sal e pimenta, comum nos métodos de classificação baseados em pixel foi aplicado um filtro de moda com o Kernel 3. A Figura 4.6 apresenta uma área em detalhe antes e depois da aplicação do filtro de moda.

Figura 4.6 – Resultado da aplicação de filtro de moda.



A região ilustrada está localizada próxima à cidade de Mariana. A classificação (a) representa o produto obtido pelo algoritmo Random Forest; e, (b) o resultado da aplicação do filtro de moda.

Fonte: Produção do autor.

Foi também criada uma máscara de agricultura aplicada nesta classificação. Como a área apresenta uma predominância de agricultura do tipo familiar, a dimensão dos talhões e mistura entre cultivos dificulta a identificação automática destas áreas. Outra característica identificada na região é o plantio de cana-de-açúcar, não na sua forma extensiva, mas para o complemento da alimentação do pastoreio, presente em pequenas áreas. A Figura 4.7 apresenta duas áreas de plantio de cana-de-açúcar na área de

estudo. Neste caso, a retirada da cana-de-açúcar ocorre de forma lenta e gradativa, deixando uma parcela de vegetação e outra de solo-exposto coberto por palha, ilustrada na imagem à direita da Figura 4.7. Isto dificulta a discriminação da classe na classificação e aumenta a confusão entre as classes. Pelos motivos apresentados, a classe agricultura não foi considerada na classificação inicial e foi posteriormente adicionada.

Figura 4.7 – Imagens de áreas de produção de cana-de-açúcar na região de Mariana/MG.

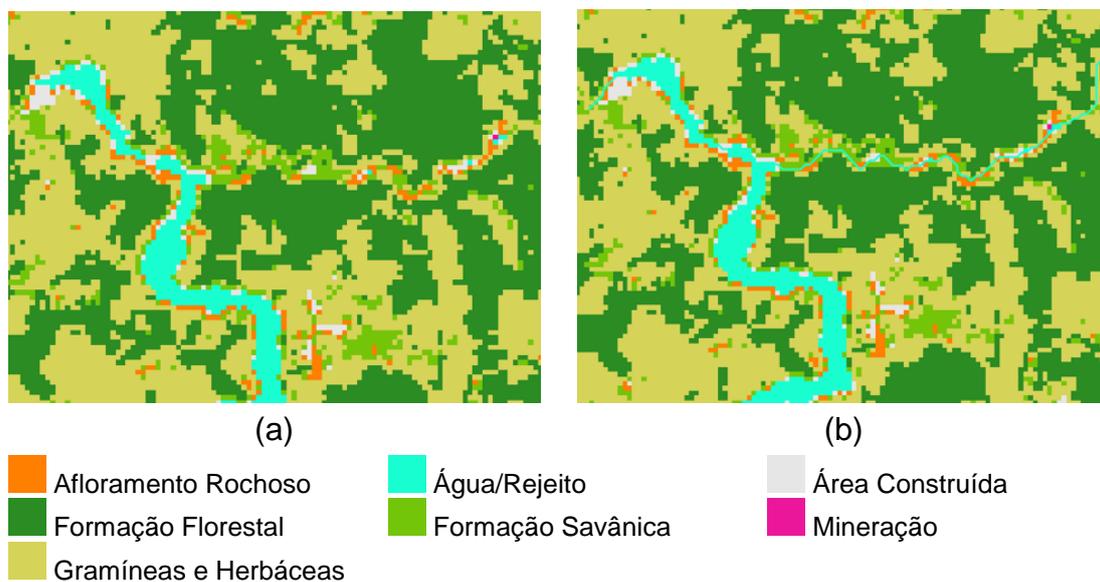


Fonte: Google Street View.

Quanto ao pós-processamento, uma máscara de água foi aplicada para refinar os resultados na classificação. Neste caso, a limitação do resultado da classificação foi devido à resolução espacial de 30 m, não adequada para identificar com precisão alguns cursos hídricos da região. Assim, a classificação foi eficiente apenas para cursos hídricos mais largos, como ilustra a Figura 4.8.

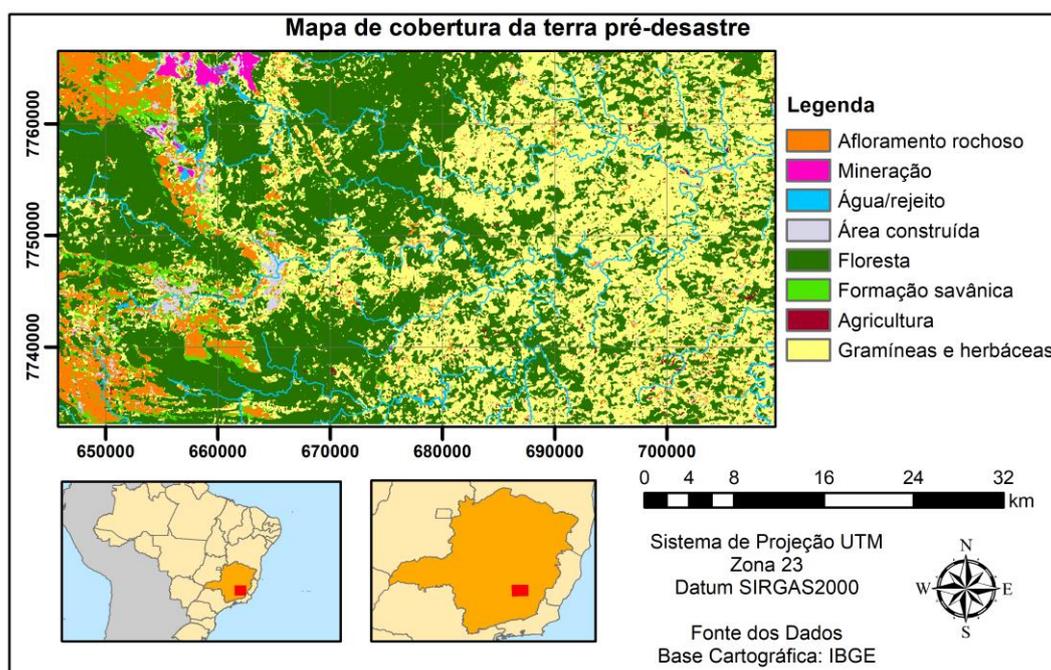
Após estes processamentos foi então gerado o Mapa de cobertura da terra pré-desastre, apresentado na Figura 4.9. Este mapa foi comparado a um mapa de referência obtido pela combinação dos mapeamentos já existentes referentes ao mesmo período. Esta comparação foi feita com base no cálculo de valores de acurácia e matriz de confusão. Nestes cálculos foram considerados 1158935 pixels, referente a aproximadamente 48% dos pixels da classificação.

Figura 4.8 – Produtos de classificação pré-desastre antes e após a aplicação da máscara de água.



Fonte: Produção do autor.

Figura 4.9 – Mapa de cobertura da terra pré-desastre.



Fonte: Produção do autor.

O resultado desta validação mostrou que a classificação e as metodologias adotadas foram eficientes, com valor de acurácia global de 88,29 %. A Tabela 4.3 apresenta a matriz de confusão para a validação do mapa de cobertura da terra pré-desastre. Os resultados de acurácia do produtor e acurácia do

usuário mostram que a grande maioria das classes apresentou mais omissão que comissão. A classe formação savânica apresentou os menores valores de acurácias do usuário e do produtor. A classe área construída também apresentou uma acurácia do produtor baixa, de 34,64%, mostrando que houve problemas de omissão nesta classe e que talvez o ideal seria uma quantidade maior de amostras na representação da mesma. A diversidade de materiais presentes nas áreas urbanas, como diversos tipos de telhados e asfaltos, pode explicar a dificuldade de representação desta classe. Já as classes com melhor desempenho foram formação florestal, seguido de afloramento rochoso e mineração. A Figura 4.10 apresenta uma comparação entre o mapeamento desenvolvido neste trabalho e os mapas utilizados na validação.

Tabela 4.3 – Matriz de confusão referente à classificação pré-desastre utilizando a série temporal de NDVI e métricas fenológicas.

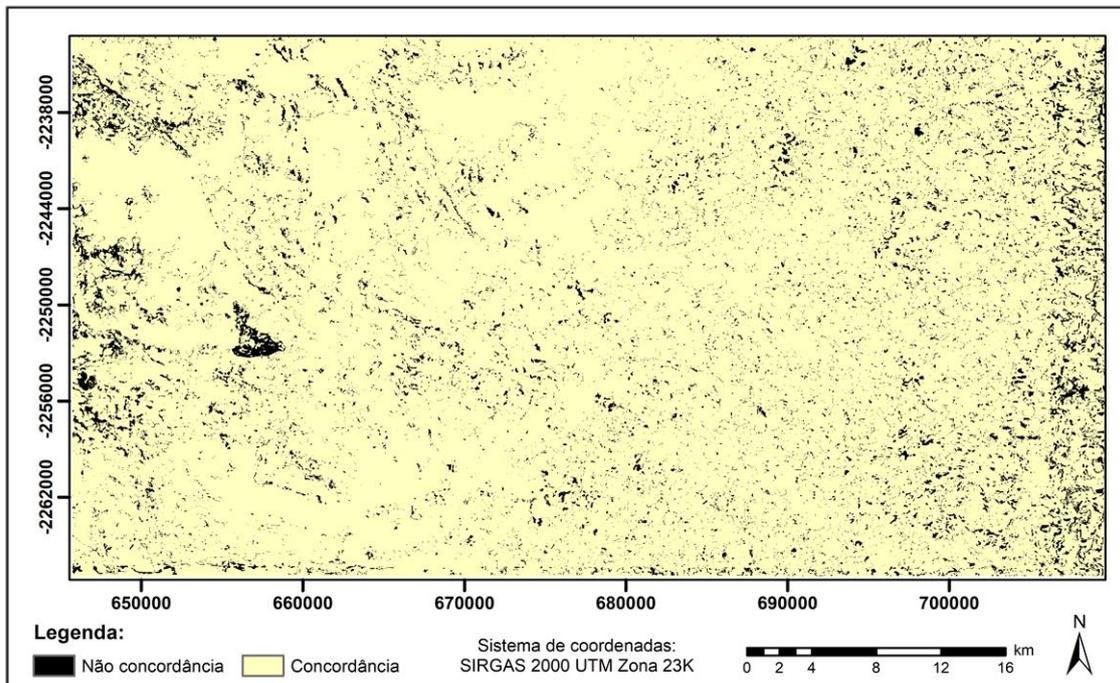
Classes	Real (Pixels)						
	Afloramento Rochoso	Mineração	Água/rejeito	Área Construída	Formação Florestal	Formação Savânica	Agricultura/Veg. rasteira
Afloramento Rochoso	59344	6	8	1327	315	4627	742
Mineração	1	458	57	7	0	0	0
Água/rejeito	27	0	1012	29	36	8	205
Área Construída	725	191	2	4810	74	175	213
Formação Florestal	1501	46	186	329	519841	8286	35745
Formação Savânica	1208	2	0	29	20	1747	35
Agricultura/Veg. rasteira	18921	0	893	7355	42597	9829	435966
Acurácia do Produtor (%)	72,61	65,15	46,90	34,64	92,35	7,08	92,19
Acurácia do Usuário (%)	89,42	87,57	76,96	77,71	92,92	57,45	84,62
Acurácia Global (%)	88,29						

Fonte: Produção do autor.

Apesar dos valores baixos de acurácias do produtor e do usuário para as classes formação savânica e área construída, os resultados estão em concordância com a validação feita por amostras de teste no *Random Forest*. As acurácias mais baixas de acordo com as amostras de teste foram para estas duas classes, o que reforça a coerência dos valores obtidos

anteriormente. Porém, a classe água, apresentou valores inferiores de acurácia. Como já havia sido observado anteriormente esta classe apresenta um número de amostras bem restrito considerada a largura dos cursos hídricos em relação à resolução espacial utilizada.

Figura 4.10 – Concordância entre o mapa de cobertura da terra pré-desastre e os mapeamentos do Mapbiomas, ANA e SOS Mata Atlântica.

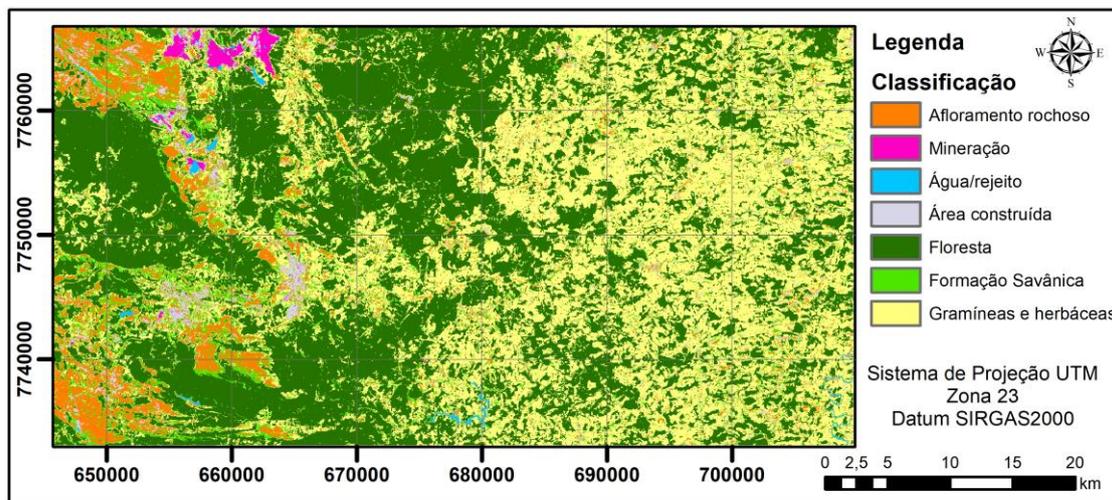


Fonte: Produção do autor.

4.2.3 Classificação pós-desastre

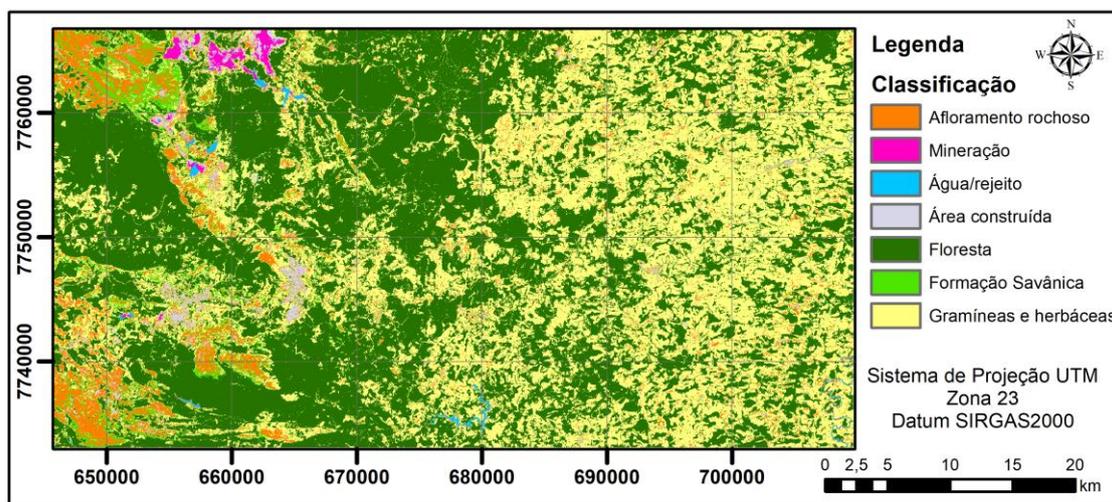
Os resultados das classificações da série temporal de NDVI, considerando as imagens de novembro de 2016 a setembro de 2019, são apresentados nesta seção. A Figura 4.11 apresenta o resultado da classificação RF para a série temporal de NDVI. A Figura 4.12 apresenta o resultado para a série temporal de NDVI associada às métricas fenológicas. Visualmente, não foi possível identificar grandes diferenças entre a classificação das séries temporais de dados NDVI e a classificação das séries temporais de NDVI e métricas fenológicas. A classificação contendo as métricas fenológicas aparentemente apresenta menor presença de ruídos do tipo sal e pimenta. A Figura 4.13 apresenta o detalhamento de uma área para ambas as classificações.

Figura 4.11 – Classificação das séries temporais de NDVI pós-desastre.



Fonte: Produção do autor.

Figura 4.12 – Classificação das séries temporais de NDVI e métricas pós-desastre.

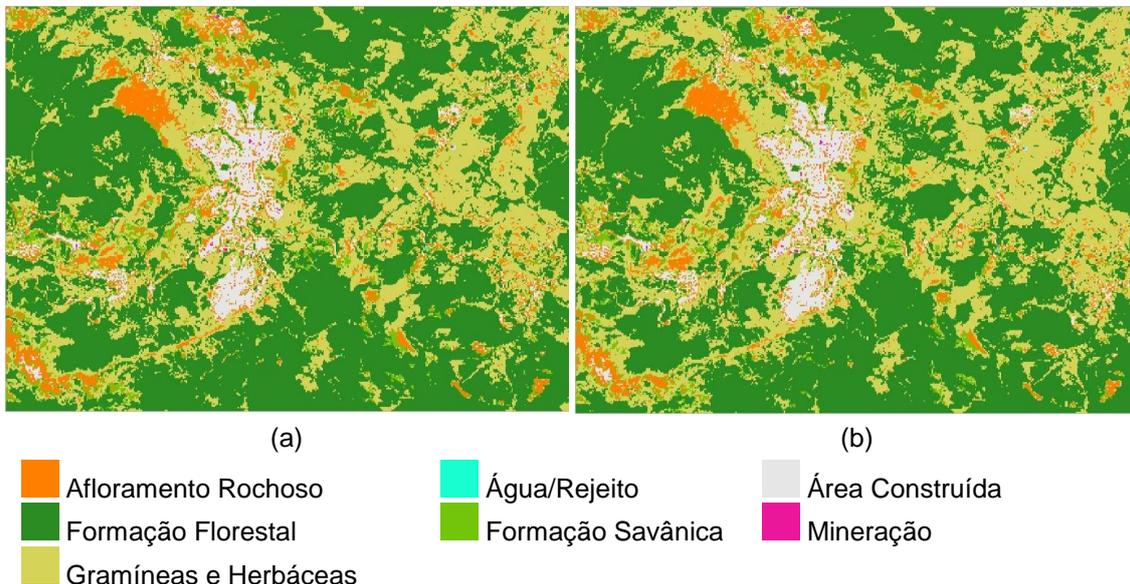


Fonte: Produção do autor.

A Tabela 4.4 apresenta a matriz de confusão referente a classificação das séries temporais de NDVI. Por outro lado, a Tabela 4.5 apresenta os resultados obtidos ao se considerar as séries temporais de NDVI e as métricas fenológicas na classificação. Os resultados em termo de confusão entre classes foram bastante similares aos apresentados na classificação pré-desastre. As classificações apresentaram confusão entre as classes afloramento rochoso e formação savânica, sendo que a classificação com as séries temporais de NDVI e as métricas fenológicas também apresentou confusão entre afloramento rochoso e

a classe gramíneas e herbáceas. Ambas as classificações também apresentaram confusão entre as classes área construída e mineração.

Figura 4.13 – Comparação entre as classificações para o período pós-desastre.



O produto (a) corresponde à classificação da série temporal de dados NDVI, e (b) à classificação utilizando a série temporal de NDVI em conjunto com métricas fenológicas.

Fonte: Produção do autor.

Tabela 4.4 – Matriz de confusão da classificação pós-desastre utilizando as séries temporais de NDVI.

Classes	Real (Pixels)						
	Afloramento Rochoso	Mineração	Água/rejeito	Área Construída	Formação Florestal	Formação Savânica	Gramíneas e Herbáceas
Afloramento Rochoso	9	0	0	0	0	2	1
Mineração	0	3	1	1	0	0	0
Água/rejeito	0	0	6	0	0	0	0
Área Construída	0	2	0	5	0	0	0
Formação Florestal	0	0	0	0	12	0	0
Formação Savânica	2	0	0	0	0	1	0
Gramíneas e Herbáceas	0	0	0	0	0	2	8
Acurácia do Produtor (%)	81,82	60,00	85,71	83,33	100,00	20,00	88,89
Acurácia do Usuário (%)	75,00	60,00	100,00	71,43	100,00	33,33	80,00
Acurácia Global (%)	80,00						

Fonte: Produção do autor.

Por outro lado, diferentemente das classificações pré-desastre, a classe área construída já não apresentou confusão com a classe afloramento rochoso. Já as classes formação savânica e gramíneas e herbáceas que não apresentaram confusão na classificação pré-desastre, apresentaram confusão entre si. Conforme matriz de confusão, a classe água/rejeito novamente não apresentou confusão na classificação das séries temporais de dados NDVI. Porém, apresentou confusão na classificação que inclui as métricas fenológicas. A utilização das métricas fenológicas eliminou a confusão entre as classes gramíneas e herbáceas e afloramento rochoso diminuiu a confusão entre a classe gramíneas e herbáceas e a classe formação campestre. A classificação que usou as métricas fenológicas também reduziu a confusão entre afloramento rochoso e formação savânica. Além de eliminar a confusão entre as classes água/rejeito e mineração.

Tabela 4.5 – Matriz de confusão da classificação pós-desastre utilizando as séries temporais de dados NDVI e métricas fenológicas.

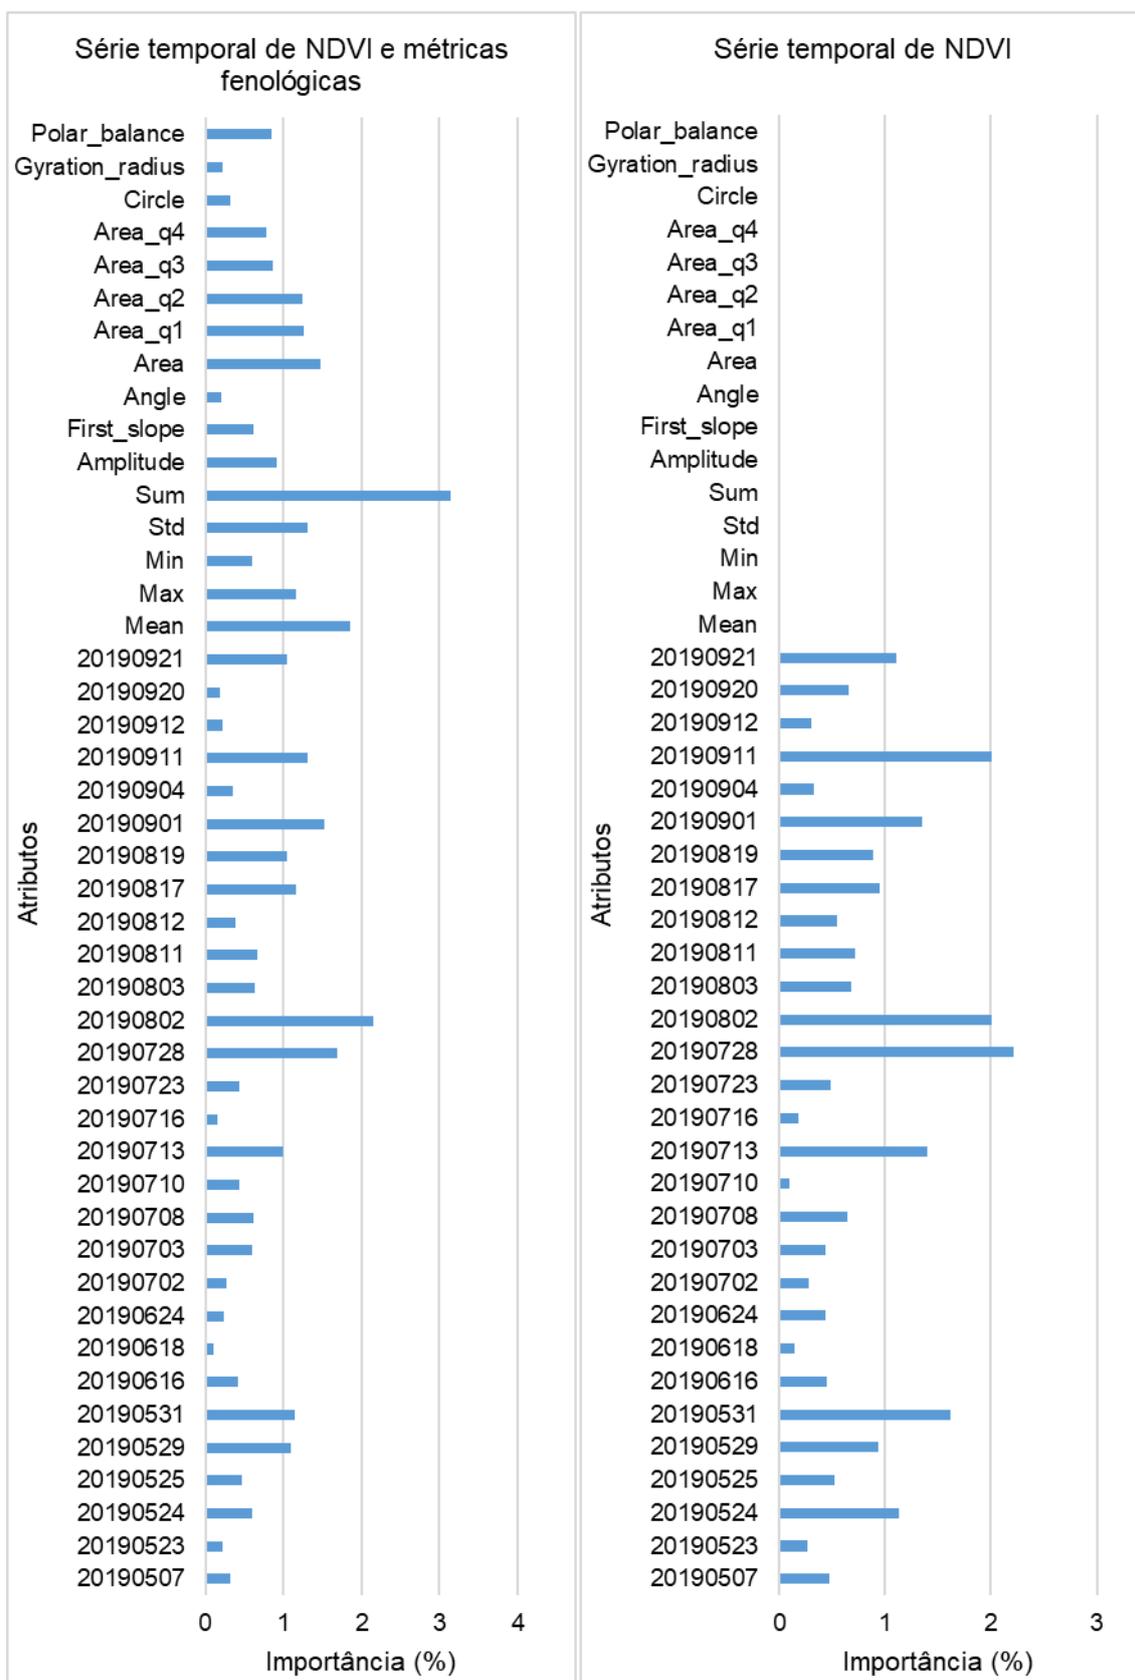
Classes	Real (Pixels)						
	Afloramento Rochoso	Mineração	Água/rejeito	Área Construída	Formação Florestal	Formação Savânica	Gramíneas e Herbáceas
Afloramento Rochoso	9	0	0	0	0	2	0
Mineração	0	3	0	1	0	0	0
Água/rejeito	0	0	7	0	0	0	0
Área Construída	0	2	0	5	0	0	0
Formação Florestal	0	0	0	0	12	0	0
Formação Savânica	1	0	0	0	0	2	0
Gramíneas e Herbáceas	1	0	0	0	0	1	9
Acurácia do Produtor (%)	81,82	60,00	100,00	83,33	100,00	40,00	100,00
Acurácia do Usuário (%)	81,82	75,00	100,00	71,43	100,00	66,67	81,82
Acurácia Global (%)	85,45						

Fonte: Produção do autor.

A Figura 4.14 apresenta os gráficos com a importância dos atributos de cada classificação realizada. A utilização das métricas fenológicas diminuiu a importância de algumas imagens na classificação. Na classificação das séries

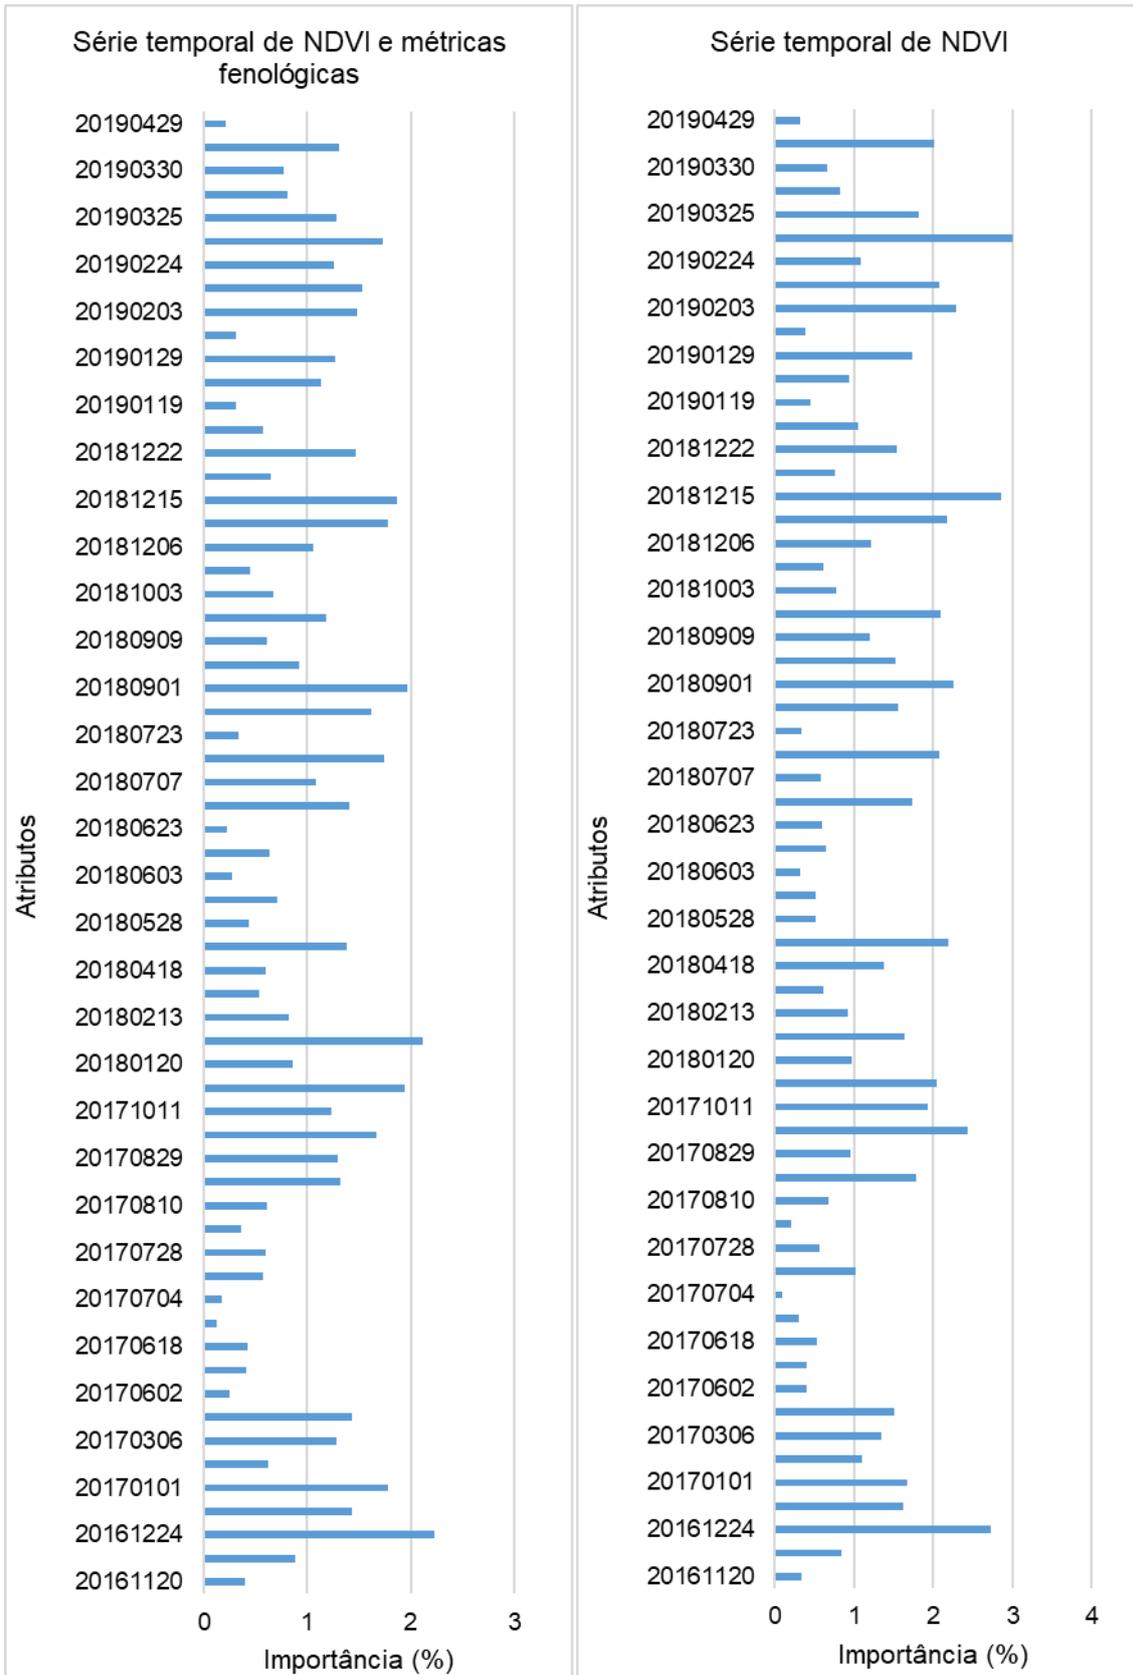
temporais de NDVI, três datas se destacaram com importâncias próximas a 3%: sendo elas 20161224 (Landsat-7), 20181215 (Sentinel-2) e 20190315 (Sentinel-2). Quando utilizadas as métricas fenológicas, a importância das imagens diminuiu para valores próximos a 2%. O destaque fica para a métrica Soma (Sum), que assume um valor de importância superior a 3%. Apesar de 2 e 3% parecerem valores baixos de importância, em relação a quantidade total de atributos estas porcentagens são as mais elevadas. Lembrando que foram consideradas 92 imagens orbitais e 16 métricas fenológicas para a classificação.

Figura 4.14 – Importância de cada atributo utilizado nas classificações pós-desastre.



continua

Figura 4.14 – Conclusão.

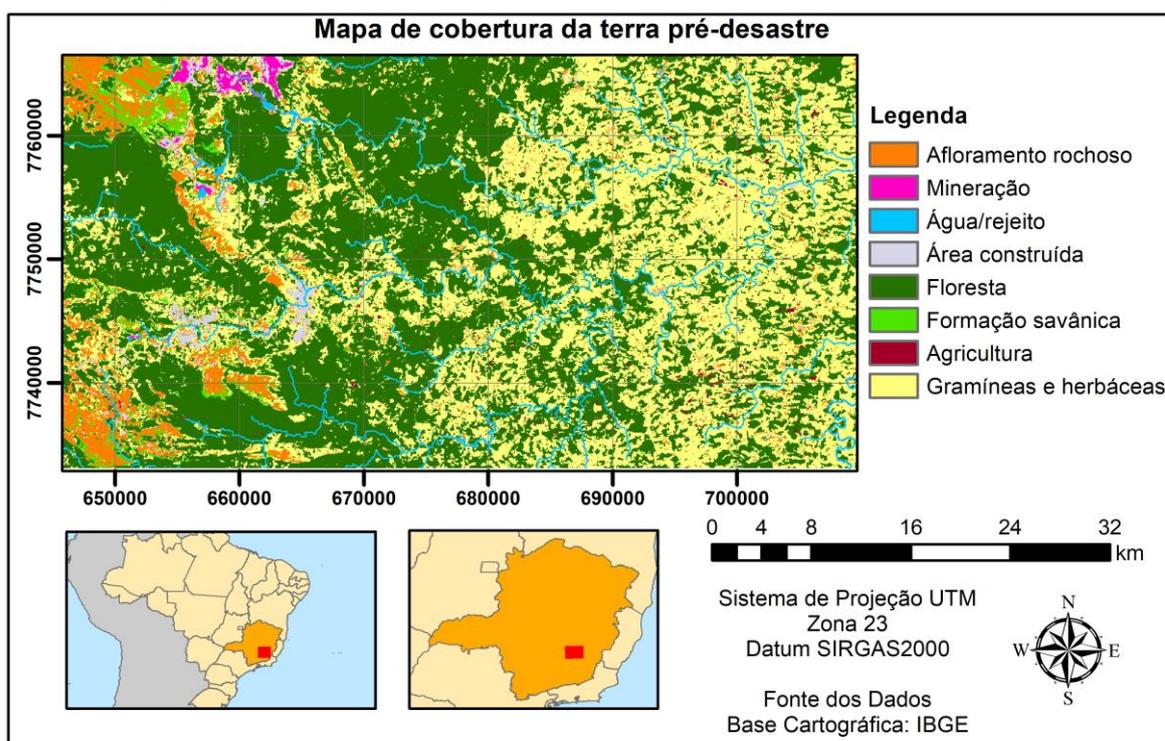


Fonte: Produção do autor.

4.2.4 Pós-processamento da classificação pós-desastre

A classificação pós-desastre da série temporal de dados NDVI e métricas fenológicas apresentou melhor resultado em relação a utilização apenas das séries temporais de NDVI, apresentando 5% a mais de acurácia. Por este motivo, esta classificação foi adotada para a criação do Mapa de cobertura da terra pós-desastre. As etapas de pós-processamento aplicadas foram as mesmas usadas para a classificação pré-desastre: filtro de moda com kernel 3, máscara de agricultura e máscara de água. A Figura 4.15 apresenta o Mapa de cobertura da terra pós-desastre para a área de estudo.

Figura 4.15 – Mapa de cobertura da terra do cenário pós-desastre.



Fonte: Produção do autor.

4.2.5 Comparação das classificações pré e pós-desastre

Esta seção apresenta uma comparação entre os resultados das classificações realizadas neste trabalho. É importante destacar que as principais diferenças entre as classificações pré-desastre e pós-desastre, além das datas utilizadas, é a densidade da série temporal e a inserção das imagens Sentinel-2 na série temporal usada na classificação pós-desastre. A Tabela 4.6 apresenta as

acurácias global, do produtor e do usuário, para as classificações pré-desastre e pós-desastre, utilizando as séries temporais de NDVI e as séries temporais de NDVI em conjunto com as métricas fenológicas.

Tabela 4.6 – Acurácias obtidas nas classificações.

Classes	Pré-desastre				Pós-desastre			
	Série temporal de NDVI		Série temporal de NDVI e métricas		Série temporal de NDVI		Série temporal de NDVI e métricas	
	Ac. do Produtor	Ac. do Usuário	Ac. do Produtor	Ac. do Usuário	Ac. do Produtor	Ac. do Usuário	Ac. do Produtor	Ac. do Usuário
Afloramento Rochoso	72,73	66,67	72,73	80,00	81,82	75,00	81,82	81,82
Água/rejeito	100,00	100,00	100,00	100,00	85,71	100,00	100,00	100,00
Mineração	50,00	50,00	50,00	50,00	60,00	60,00	60,00	75,00
Área Construída	66,67	57,14	66,67	57,14	83,33	71,43	83,33	71,43
Formação Florestal	100,00	92,31	100,00	92,31	100,00	100,00	100,00	100,00
Formação Savânica	40,00	40,00	60,00	60,00	20,00	33,33	40,00	66,67
Gramíneas e Herbáceas	62,50	100,00	87,50	100,00	88,89	80,00	100,00	81,82
Acurácia Global (%)	75,47		81,13		80,00		85,45	

Fonte: Produção do autor.

Analisando as acurácias do usuário e do produtor, nenhuma destas sofreu perda quando aplicadas as métricas fenológicas. As classes gramíneas e herbáceas, afloramento rochoso e formação savânica, apresentaram ganhos consideráveis. Para a classificação pós-desastre, a classe mineração também apresentou aumento na acurácia do usuário de 60% para 75%. Em ambos os casos, classificação pré-desastre ou pós-desastre, os valores de acurácia global apresentaram mais de 5% de aumento ao se considerar as métricas fenológicas. Assim, para ambos os períodos analisados, os melhores resultados de classificação foram obtidos com a utilização das métricas fenológicas associadas à série temporal de dados NDVI.

A classificação pré-desastre apresentou resultados similares aos resultados apresentados por outros mapeamentos já existentes. Ao se comparar a classificação obtida com o mapa de referência, observou-se uma concordância de 88,29%.

4.3 Análises de mudanças da cobertura da terra causadas pelo desastre

4.3.1 Séries temporais de NDVI nas áreas afetadas pelo desastre

Neste trabalho, algumas análises, utilizando as séries temporais de NDVI, foram feitas na tentativa de melhor compreender as mudanças da cobertura da terra causadas pelo desastre de Mariana. Para estas análises, foram utilizadas as séries temporais de NDVI do período de abril 2013 a setembro de 2019. A Figura 4.16 ilustra cinco exemplos de áreas afetadas, e as respectivas séries temporais entre 2013 e 2019. Estas séries representam a dinâmica de cobertura da terra das áreas antes e depois do evento, que permitem visualizar cinco padrões distintos de mudanças da cobertura da terra.

O gráfico mostra a diminuição abrupta dos valores de NDVI observada a partir da ocorrência do desastre (Figura 4.16). Em geral, os valores de NDVI das séries temporais analisadas apresentaram uma redução brusca correspondente a datas posteriores a data de ocorrência do desastre, sendo observado valores próximos de zero. No decorrer do tempo, após o desastre, estas curvas de valores de NDVI mostram alteração, inclusive para algumas amostras há o aumento da sazonalidade da resposta. As amostras 1 e 2 tiveram sua vegetação florestal completamente removida devido ao desastre. No período anterior ao desastre, estas áreas apresentaram padrões similares na série temporal de NDVI. Por outro lado, essas amostras apresentaram padrões bem distintos após o evento, a amostra 1 manteve-se com valores próximos a 0, enquanto a amostra 2 apresentou aumento nos valores de NDVI a partir de meados de 2016.

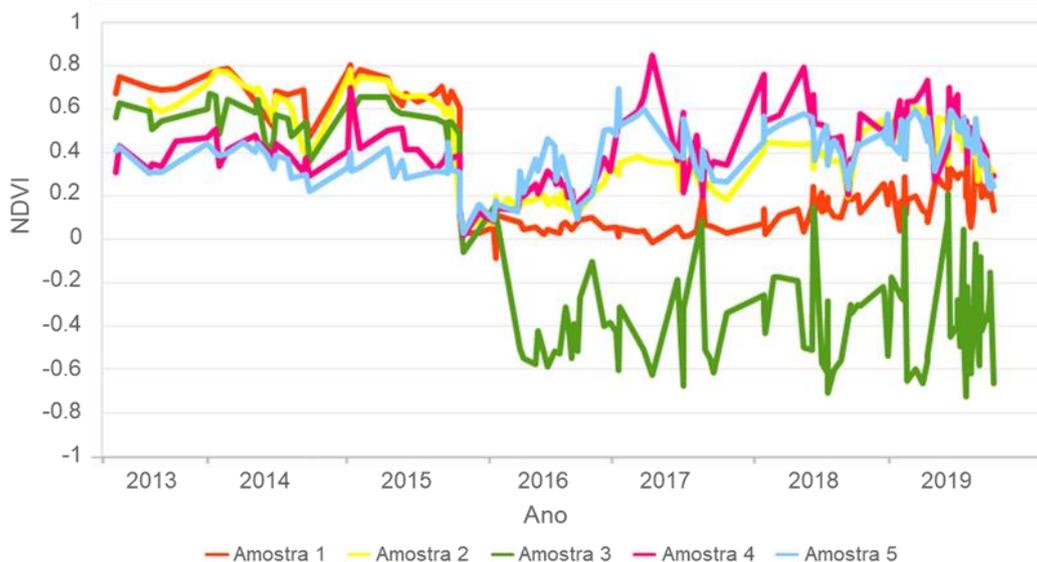
A amostra 3 apresenta um comportamento distinto das demais áreas de gramíneas e herbáceas apresentadas na Figura 4.16, por se tratar de uma área alagável com maior concentração de arbustos. A amostra 3 apresentou não apenas uma redução dos valores de NDVI devido ao desastre, mas também outra diminuição brusca no NDVI nos primeiros meses de 2016. Esta diminuição foi causada pela presença de água, após estas áreas serem alagadas devido a construção de diques de contenção. As amostras 4 e 5 com padrões de gramíneas e herbáceas, referentes a uma área de pastagem e outra com

presença de vegetação arbustiva de baixo porte, foram cobertas por lama devido ao desastre. Após o desastre, a partir dos primeiros meses de 2016, estas áreas começam a ter um aumento do NDVI para valores próximos de 0,4.

Figura 4.16 – Exemplo de cinco séries temporais de NDVI de áreas afetadas pelo desastre de Mariana.



(a)



(b)

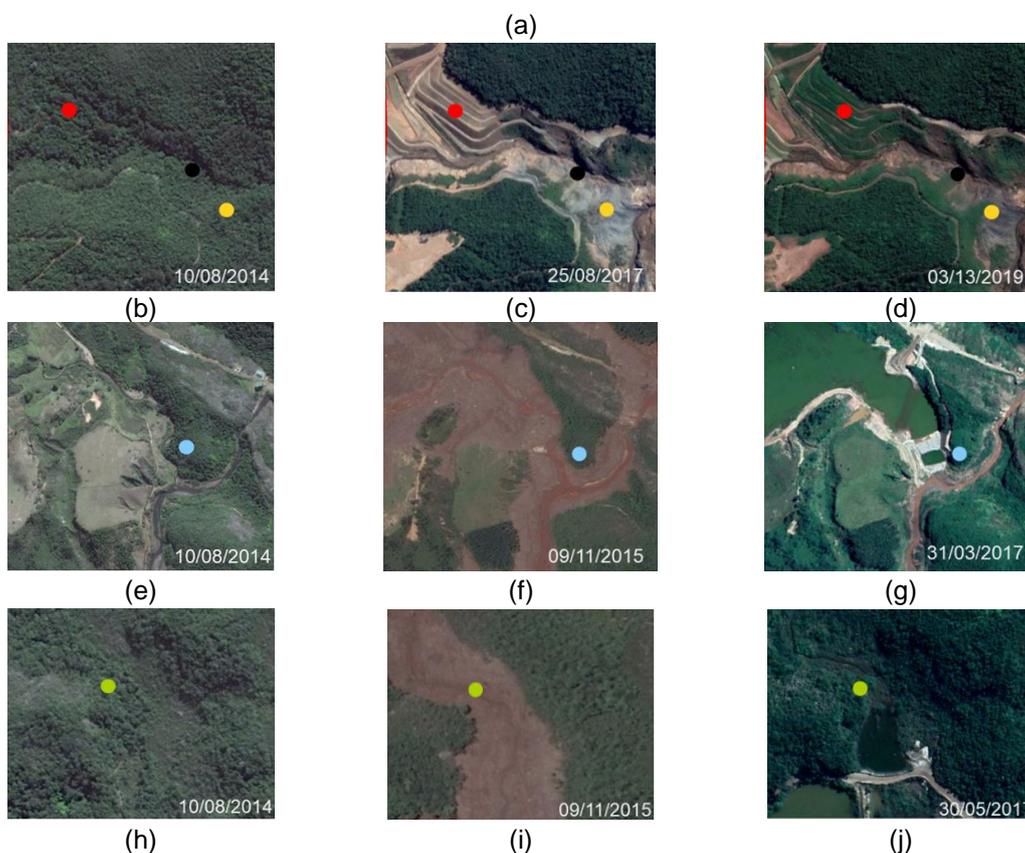
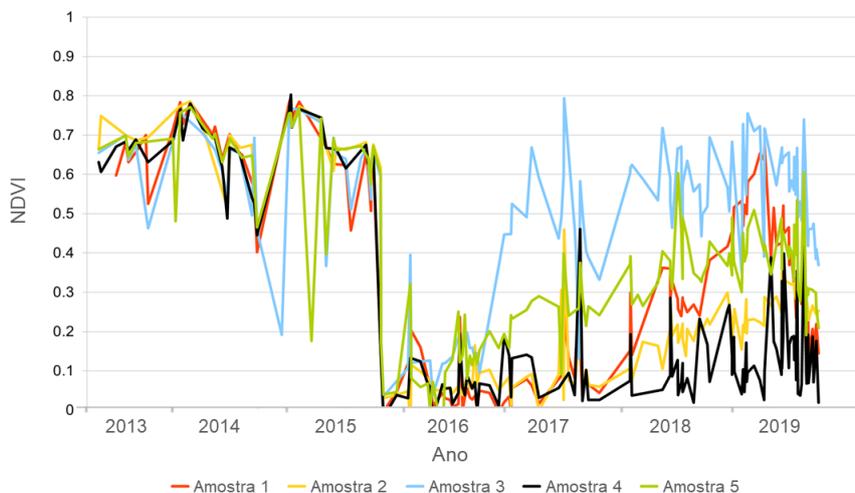
A figura (a) apresenta a localização de cinco regiões selecionadas na área afetada pelo desastre de Mariana. O gráfico (b) apresenta as curvas de NDVI para os pixels correspondentes a cada região (amostra 3X3). Cada curva é referente a mediana entre os valores de NDVI de nove pixels. As amostras 1 e 2 são referentes a áreas de formação florestal, as amostras 3, 4 e 5 referem-se a áreas com presença de gramíneas e herbáceas, antes do desastre.

Fonte: Produção do autor.

A Figura 4.17 apresenta cinco séries temporais de NDVI referentes a cinco regiões em áreas de floresta afetadas pelo desastre, além de apresentar imagens que mostram as mudanças na cobertura da terra nessas regiões amostradas. Todas as séries apresentam uma redução dos valores de NDVI após a data de ocorrência do desastre. Nos dois primeiros anos após o desastre, as amostras 1, 2 e 4 seguiram um mesmo padrão de NDVI, possivelmente devido à presença predominante de lama. No ano de 2018, estas áreas começaram a apresentar um aumento nos valores de NDVI. Apesar deste aumento, as amostras 2 e 4 permanecem com valores baixos em torno de 0,2, sem indicativos de um retorno da vegetação. Na área referente à amostra 1, pode-se observar um aumento mais acentuado nos valores de NDVI. Na imagem de 25/08/2017 em (c) é possível observar que esta área teve a reconformação de taludes, um indicativo de que possivelmente a área passou por ação de recuperação da vegetação. A imagem de 13/03/2019 (d) mostra a área com uma cobertura vegetal de baixo porte.

A amostra 3 pertence a uma das áreas apontadas pela Operação Watu como tendo sofrido ações de recuperação (SISEMA, 2018). Após o ano de 2017, esta área passa a apresentar índices mais elevados de NDVI devido à presença de vegetação. Já a amostra 5 apresentou um aumento mais gradual dos valores de NDVI com início em meados de 2016 e seguiu em aumento durante o período de dois anos. Pelas imagens do Google Earth TM, é possível observar que a área apresentou uma mudança saindo de solo exposto para gramíneas e herbáceas e posteriormente evoluindo para uma vegetação mais arbustiva. Vale destacar que esta região está localizada na borda de áreas não atingidas pelo desastre e com presença de vegetação florestal. Ainda assim, notou-se que foram necessários mais de 2 anos para o início do processo de recuperação da vegetação.

Figura 4.17 – Séries temporais de NDVI definidas a partir de amostras coletadas em áreas de floresta afetadas pelo desastre.



A figura (a) apresenta séries temporais de NDVI para cinco regiões amostradas em áreas de floresta (antes do desastre). Cada curva é referente a mediana entre os valores de NDVI de nove pixels. As amostras são ilustradas em imagens Google Earth™, referentes a diferentes datas/cenários. As amostras 1, 2 e 4 são ilustradas nas imagens (b), (c) e (d). A amostra 3 é ilustrada nas figuras (e), (f) e (g). A amostra 5 é ilustrada nas figuras (h), (i) e (j).

Fonte: Produção do autor.

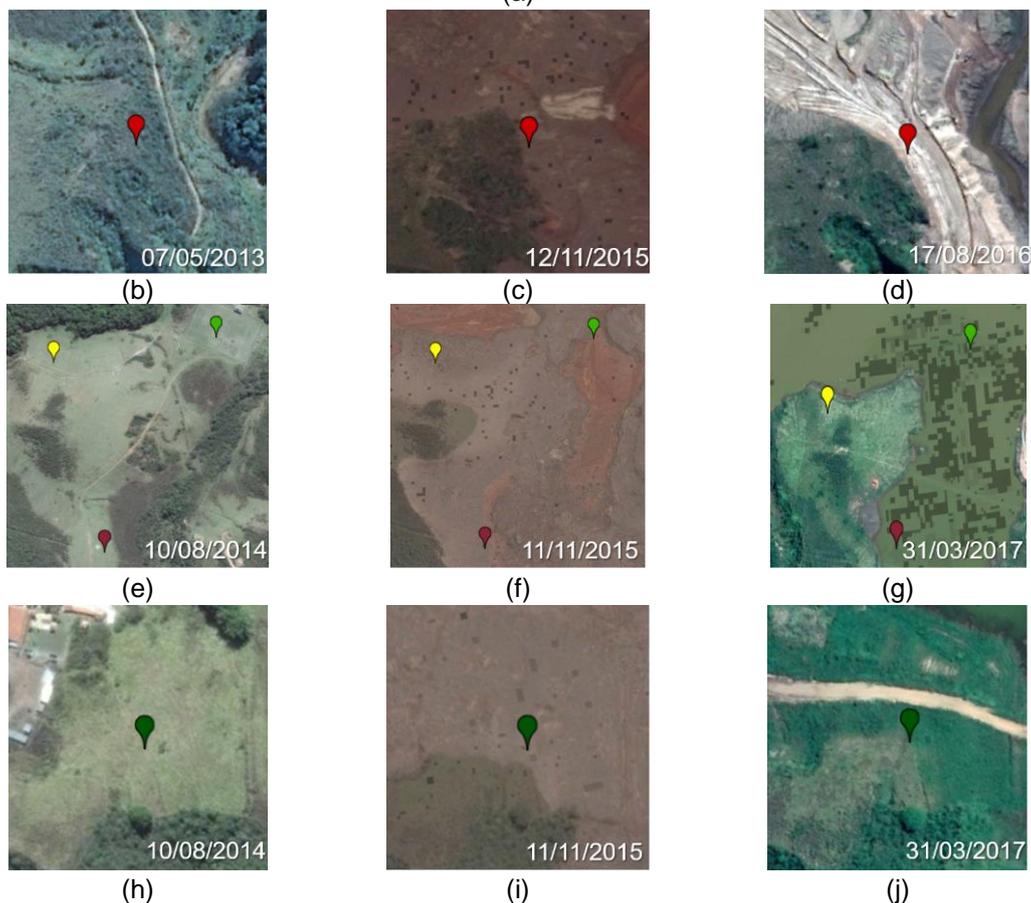
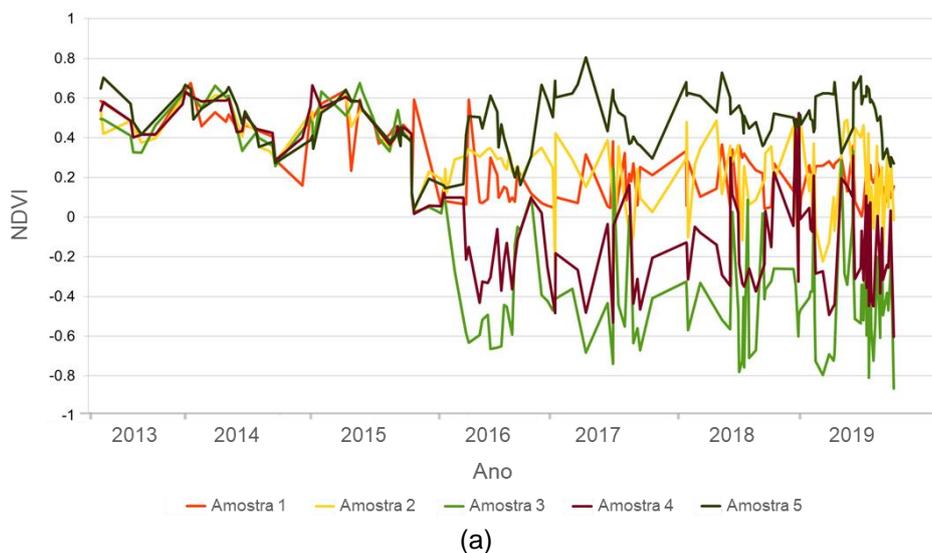
A Figura 4.18 mostra cinco séries temporais de NDVI para áreas caracterizadas antes do desastre com presença de gramíneas e herbáceas. Na data do

desastre, todas as séries apresentaram redução nos valores de NDVI para valores próximos de zero. As séries temporais de NDVI referentes às amostras 1 e 2 passaram a apresentar valores próximos de 0,2. Por outro lado, as séries temporais referentes às amostras 3 e 4 apresentaram uma redução significativa dos valores NDVI, apresentando valores negativos de NDVI após a ocorrência do evento. Esta situação pode ser explicada pelo alagamento dessas regiões pela construção do dique de contenção (S4), observe em (g). Já a série temporal referente à amostra 5 indica, a partir de 2017, uma recuperação da cobertura da terra, com a presença de gramíneas e herbáceas (j) com padrões similares àqueles observados no período pré-desastre.

A Figura 4.19 mostra a variação do NDVI para duas regiões, R1 e R2, que foram afetadas pelo desastre e são localizadas na área de APP do Rio Gualaxo do Norte. Ambas áreas vêm passando por ações de recuperação pela Renova (SISEMA, 2018), apresentando padrões de variação similares nas curvas de média dos valores de NDVI. O desvio padrão para ambas as séries temporais se apresentou maior nas épocas de maior precipitação para a área de estudo, estando possivelmente relacionado a ruídos devido a presença de nuvens, apesar dos dados terem passado por um processo de remoção das mesmas.

Os valores de NDVI nas séries temporais (b) e (c), na Figura 4.19, apresentam a redução referente ao desastre em 2015. Em (a), as imagens de 09/11/2015 e 26/07/2016 mostram como estes pontos foram completamente tomados pela lama. A partir dos primeiros meses de 2017, estas áreas passaram a ter valores mais elevados de NDVI, e no início de 2018 os valores apresentaram outro aumento. Como mostra a imagem de 30/05/2017 em (a), estas áreas voltaram a apresentar gramíneas e herbáceas. Outras análises são apresentadas no apêndice B.

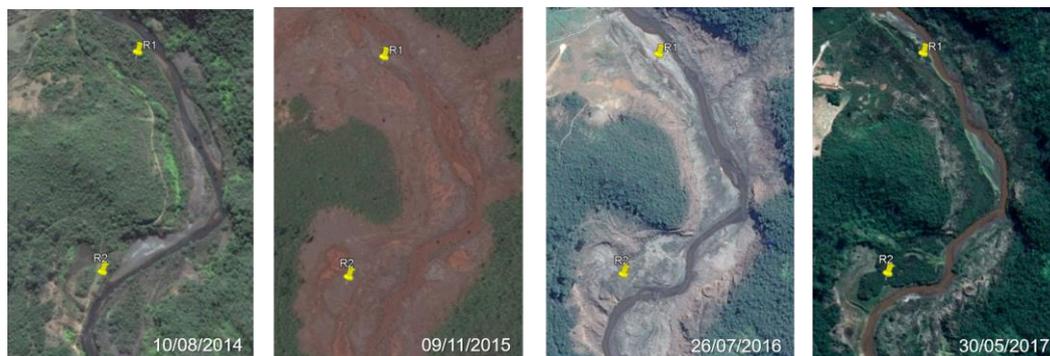
Figura 4.18 – Séries temporais de NDVI definidas a partir de amostras coletadas em áreas com presença de gramíneas e herbáceas antes do desastre e imagens dos diferentes cenários.



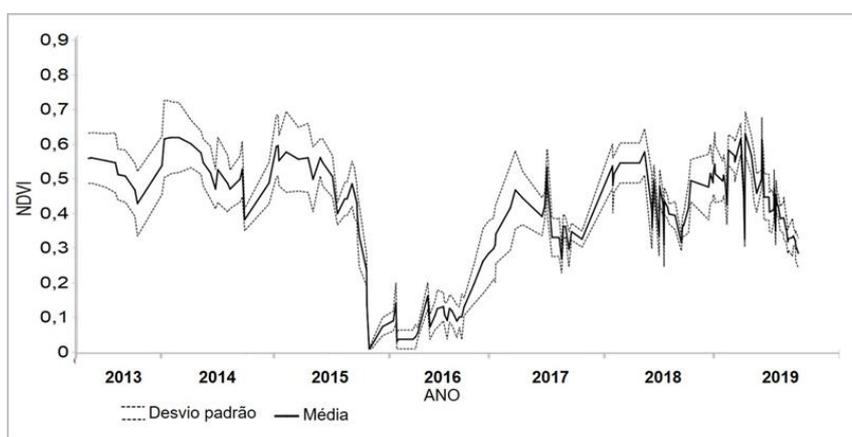
A figura (a) apresenta séries temporais de NDVI para cinco regiões amostradas em áreas de gramíneas e herbáceas (antes do desastre), cada curva é referente a mediana entre os valores de NDVI de nove pixels. As amostras são ilustradas em imagens Google Earth™, referentes a diferentes datas/cenários. A amostra 1 é ilustrada nas figuras (b), (c) e (d). As amostras 2, 3 e 4 são ilustradas nas imagens (e), (f) e (g). A amostra 5 é ilustrada nas figuras (h), (i) e (j).

Fonte: Produção do autor.

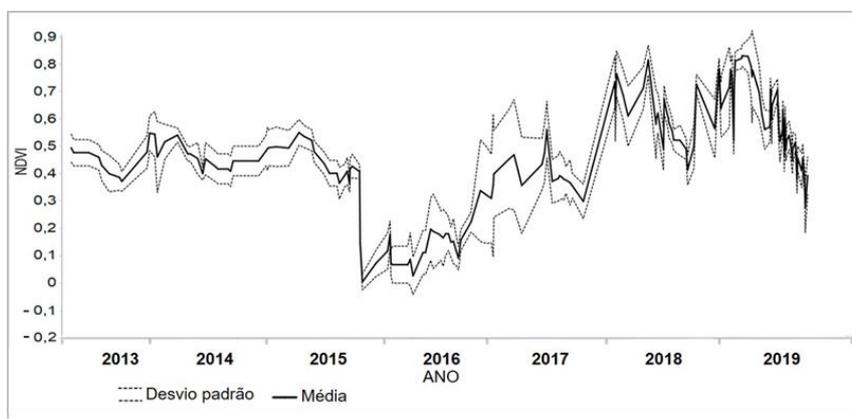
Figura 4.19 – Média e desvio padrão de nove séries temporais de NDVI referente a duas regiões afetadas pelo desastre (R1 e R2) e imagens das mudanças.



(a)



(b)



(c)

A figura (a) apresenta imagens do Google Earth TM, para quatro datas distintas na área correspondente duas regiões R1 e R2; (b) série temporal referente a média de NDVI e desvio padrão de R1; e, (c) série temporal referente a média de NDVI e desvio padrão de R2. As amostras consideradas para R1 e R2 são referentes a 3x3 pixels, estas regiões foram afetadas pelo desastre e vem passando por um processo de recuperação.

Fonte: Produção do autor.

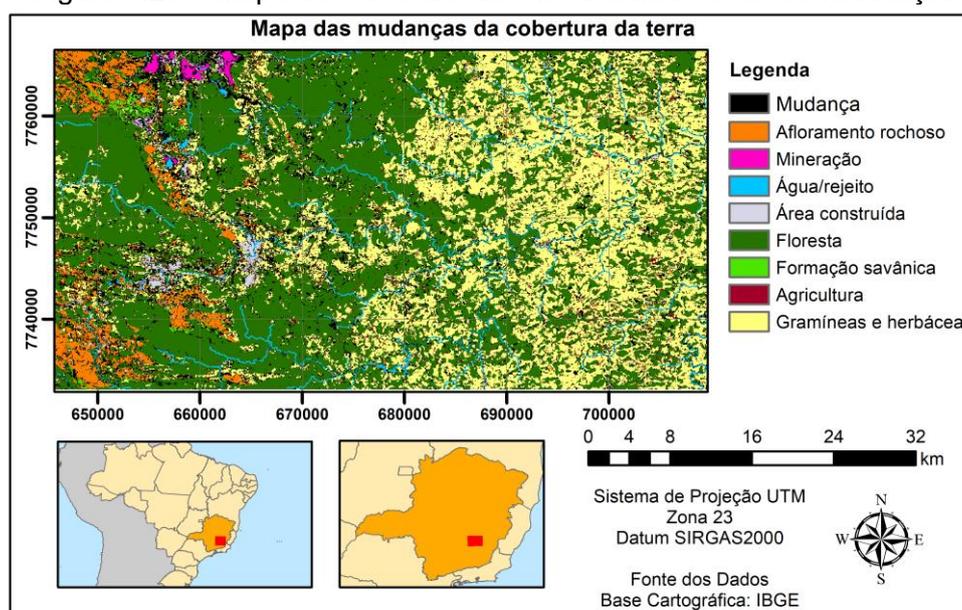
Pelas análises fica evidente o impacto direto que a lama teve na cobertura vegetal da região de Mariana/MG, seja devido à remoção total ou parcial da vegetação.

Existe também a possível influência de alterações das características dos solos que podem afetar as condições de desenvolvimento da vegetação. As séries temporais analisadas mostraram a variação no tempo de brota da vegetação, conforme o nível de impacto sofrido e o tipo de cobertura vegetal encontrado em cada região. Em geral, as análises mostraram que áreas de vegetação tem levado pelo menos 1 ano após o desastre para iniciar o processo de germinação. Por outro lado, algumas áreas levaram bem mais tempo, como pode ser observado nas amostras analisadas neste trabalho, as quais não apresentaram um aumento nos valores de NDVI, mesmo 2 anos após o desastre. As áreas que passaram por ações de recuperação tiveram este processo acelerado. Porém, a recuperação total destas áreas ainda requer mais tempo, principalmente a recuperação de áreas florestais que tiveram sua vegetação removida pela lama.

4.3.2 Mudanças da cobertura da terra

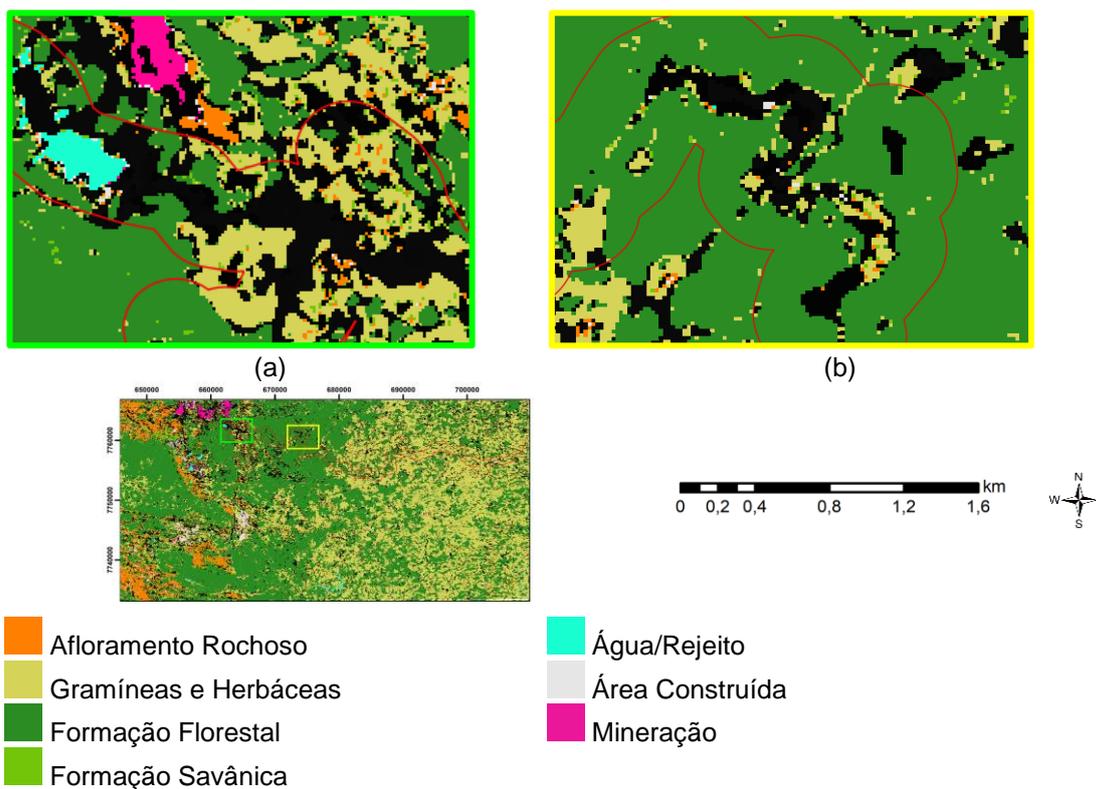
Esta seção apresenta as mudanças da cobertura da terra detectadas na área de estudo. A Figura 4.20 mostra o mapa das mudanças da cobertura da terra detectadas pela diferença entre os mapeamentos pré e pós-desastre. Vale destacar que nem todas as mudanças ocorridas na região, no período de tempo analisado, estão associadas diretamente ao desastre de Mariana.

Figura 4.20 – Mapa da cobertura da terra incluindo a classe mudança.



Fonte: Produção do autor.

Figura 4.21 – Detalhamento das mudanças da cobertura da terra.



O produtos (a) e (b) mostram em detalhe as áreas de mudança na cobertura da terra em duas áreas às margens do Rio Gualaxo do Norte.

Fonte: Produção do autor.

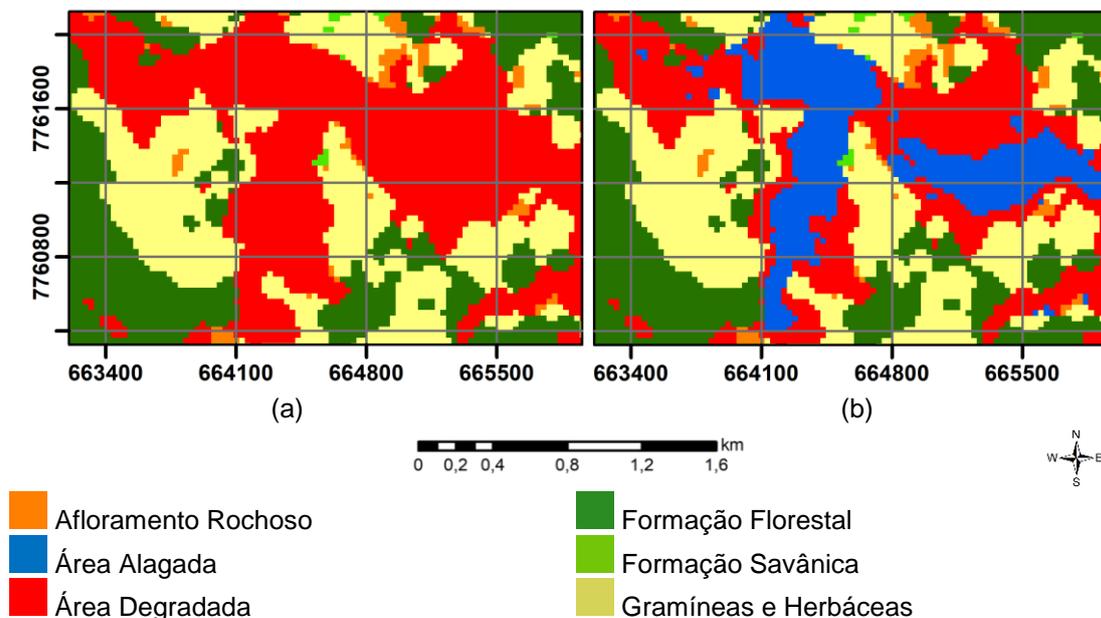
A Figura 4.21 mostra em detalhe duas regiões cuja mudança associada ao desastre foi detectada por meio dessa diferença entre os mapeamentos realizados. Pode-se identificar a mudança em uma área considerável, principalmente no seguimento dos cursos hídricos afetados pelo desastre de Mariana. Em Figura 4.21 (a), é apresentada uma das principais áreas afetadas pelo desastre em termos de mudança da cobertura da terra para a área de estudo desse trabalho. Figura 4.21 (b), mostra uma curva do Rio Gualaxo do Norte à aproximadamente 19 km da barragem de Fundão. Observe que a área apresentada em Figura 4.21 (a) corresponde a área definida para análises da mudança da cobertura da terra, onde tentamos explorar de forma mais minuciosa essas transições da cobertura da terra.

A lama do desastre causou a degração de uma área de vegetação considerável. As principais transições identificadas por meio das análises das séries temporais de NDVI (Seção 4.3.1), foram de áreas que apresentaram rebrota, áreas com

ações de recuperação e áreas alagadas. As áreas alagadas, foram áreas destruídas pelo desastre que passaram por um alagamento. Devido ao baixo número de amostras de áreas com sinais de rebrota e/ou áreas com ações de recuperação, não foi possível identificar estas áreas de forma abrangente. Porém, as áreas que sofreram degradação ou alagamento foram identificadas em uma classificação dessas transições (Figura 4.22).

Na busca por diferentes transições decorrentes das mudanças da cobertura da terra desencadeadas pelo desastre, estas áreas degradadas foram comparadas nos cenários pré e pós-desastre. As transições entre as classes de cobertura da terra foram identificadas e quantificadas, e são apresentadas em um Diagrama de Sankey (Figura 4.23).

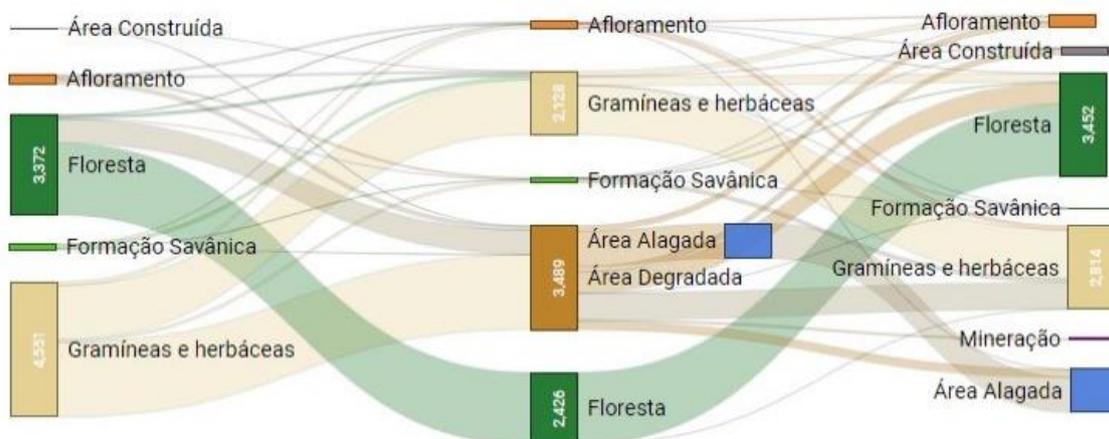
Figura 4.22 – Identificação de áreas degradadas e áreas alagadas.



O produto (a) mostra a área degradada identificada nas análises, e (b) identifica as áreas degradadas que foram alagadas.

Fonte: Produção do autor.

Figura 4.23 – Diagrama de Sankey das mudanças da cobertura da terra.



Principais mudanças da cobertura da terra identificadas e suas transições seguindo uma linha temporal da esquerda para a direita.

Fonte: Produção do autor.

A área analisada corresponde a aproximadamente 765 hectares, dos quais se identificou a degradação de mais de 300 hectares após a ocorrência do desastre. No período pré-desastre, esta área apresenta a classe gramíneas e herbáceas, como predominante, mais de 50% da área correspondente a esta classe foi degradada. Cerca de 227 hectares, da área degradada identificada, correspondem a classe gramíneas e herbáceas, 72 hectares de floresta, 2 hectares de formação savânica. Destas áreas degradadas aproximadamente 49% foram alagadas devido a construção de diques de contenção, destinados a estabilização dos rejeitos de mineração derramados no desastre de Mariana. Das demais áreas degradadas 44% apresentam presença de vegetação no cenário pós-desastre, sendo 19% pertencentes a classe floresta e 25% a classe gramíneas e herbáceas.

5 CONCLUSÕES

Esse trabalho destaca a possibilidade de utilização de séries temporais de imagens orbitais, densas e distribuídas irregularmente no tempo, para o mapeamento de cobertura da terra. Foram utilizadas imagens gratuitas, provenientes de diferentes sensores de média resolução espacial, Landsat-7, Landsat-8, CBERS-4 e Sentinel-2. Mesmo sem a utilização de tratamentos, como a harmonização ou normalização dos dados, as séries temporais em conjunto com o classificador *Random Forest* permitiram o mapeamento da cobertura da terra na área afetada pelo desastre de Mariana.

Os resultados de classificação utilizando os valores da série temporal de NDVI, em conjunto com as métricas fenológicas extraídas, produziram melhores resultados do que aquelas que utilizaram apenas os valores da série temporal. A utilização das métricas, associadas as séries temporais de NDVI, proporcionou ganhos consideráveis nas acurácias do produtor e do usuário das classes gramíneas e herbáceas, afloramento rochoso e formação savânica. Neste caso, os valores de acurácias globais das classificações foram 81,13% e 85,45% para os períodos pré-desastre e pós-desastre, respectivamente. A validação da classificação pré-desastre utilizando um mapa de referência, gerado a partir da combinação de mapeamentos provenientes de diferentes instituições, mostrou uma concordância de 88,29% entre os mapeamentos. Esse resultado reforça a eficiência da metodologia empregada.

As análises da cobertura da terra nas áreas afetadas pelo desastre de Mariana mostram que a utilização de séries temporais de NDVI podem auxiliar na identificação das mudanças ocorridas na região afetada. Nas áreas analisadas foram identificados mais de 300 hectares de áreas de vegetação degradadas. As análises das séries temporais também mostraram que as áreas atingidas têm levado entre um e dois anos para iniciar o processo de germinação natural. A regeneração destas áreas tem sido um processo lento e algumas áreas atingidas podem não ser recuperadas, como é o caso das áreas alagadas. Nas análises foram identificados aproximadamente 200 hectares de área alagada pela construção da barragem Nova Santarém, e de diques para contenção dos

rejeitos. As principais limitações identificadas são, a média resolução espacial das imagens, e a dificuldade de interpretação da curva de NDVI da série temporal densa e sem harmonização.

Vale destacar que a série temporal de NDVI da região afetada pelo desastre de Mariana, criada neste trabalho, pode ser disponível para outros tipos de aplicações e estudos. A análise das séries temporais de NDVI pode ajudar, por exemplo, no estabelecimento e avaliação de ações de recuperação. Dentre as dificuldades encontradas no desenvolvimento deste trabalho, pode-se citar a presença de nuvens nas imagens, além da necessidade de alta capacidade computacional de processamento e armazenamento do grande volume de dados.

Como sugestão para trabalhos futuros, outros índices de vegetação poderiam ser considerados na composição das séries temporais, bem como a harmonização dos dados multisensor. Outros tipos de dados poderiam auxiliar na avaliação dos resultados pós-desastre, como os dados de levantamento por VANT realizados pela Renova, ou a localização das áreas que vem sendo recuperadas.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAMI, M.; FREITAS, R. M. d.; PADOVANI, C. R.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Estudo da dinâmica espaço-temporal do bioma pantanal por meio de imagens modis. **Pesquisa agropecuária brasileira**, v. 43, n. 10, p. 1371–1378, 2008.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Encarte especial sobre a Bacia do Rio Doce - rompimento da Barragem em Mariana/MG**. Brasília-DF: Rio Doce Vivo, 2016a. 50 p. Disponível em: <http://arquivos.ana.gov.br/RioDoce/EncarteRioDoce_22_03_2016v2.pdf>. Acesso em: 22 fev. 2019.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Relatório de segurança de barragens**. Brasília-DF: ANA, 2016b. 168 p. Disponível em: <http://arquivos.ana.gov.br/cadastros/barragens/Seguranca/RelatorioSegurancaBarragens_2015.pdf>. Acesso em: 10 fev. 2019.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). Uso e ocupação do solo em moderada resolução (10 m) da Bacia do Rio Doce. **Portal de Metadados da ANA: metadados**, 2016c. Disponível em: <<https://metadados.ana.gov.br/geonetwork/srv/pt/metadata.show?id=410&currTab=distribution>>. Acesso em: 23 set. 2019.

AGUADO, O.I.O. **Práticas de manejo pecuário na microrregião de São Miguel do Araguaia, Goiás: uma análise a partir de dados de campo e de sensoriamento remoto**. 112 f. 2017. Dissertação (Mestrado em Ciências Ambientais) - Universidade Federal de Goiás, Goiânia, 2017.

AITKENHEAD, M. J. A co-evolving decision tree classification method. **Expert Systems with Applications**, v. 34, p. 18-25, 2008.

ALMEIDA, F. C.; PAIVA, L. L.; SILVEIRA, E. M. O.; WITHEY, K.; ACERBI JÚNIOR, F. W. **GIS-based multicriteria analysis to define priority areas for forest recovery following the environmental disaster in Rio Doce Basin, Brazil Franciane**. In: Anais 7º Simpósio de Geotecnologias no Pantanal, Jardim, MS. Embrapa Informática Agropecuária/INPE, 2018. p. 450-459. 2018.

ALVES, H. R. O estado de coisas inconstitucional face ao reiterado rompimento de barragens no Brasil. **(RE) PENSANDO DIREITO**, v. 9, n. 18, p. 37-61, 2019.

AMO, S. Técnicas de mineração de dados. In: JORNADA DE ATUALIZAÇÃO EM INFORMÁTICA, 2004. **Anais...** Universidade Federal de Uberlândia, 2004.

ANDERSON, L. O.; ARAGÃO, L. E. O. C.; LIMA, A.; SHIMABUKURO, Y. E. Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados

multitemporais do sensor MODIS/TERRA no estado do Mato Grosso, Amazônia brasileira. **Acta Amazonica**, v. 35, n. 4, p. 445-456, 2005.

ANDRADE, L. C. R. **Caracterização de rejeitos de mineração de ferro, in natura e segregados, para aplicação como material de construção civil**. 96f. Tese (Doutorado em Engenharia Civil) - Universidade de Viçosa, Viçosa MG, 2014. Disponível em: <http://www.locus.ufv.br/bitstream/handle/123456789/6664/texto%20completo.pdf?sequence=1>. Acesso em: 28 jan. 2020.

APTE, C.; WEISS, S. Data mining with decision trees and decision rules. **Future Generation Computer Systems**. v. 13, n. 2/3, p. 197-210, 1997.

ARANTES, T.B. **Análise de séries temporais compostas por imagens sintetizadas a partir da fusão de dados MODIS-TM**. 91 f. 2014. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras-MG, 2014.

ARVOR, D.; JONATHAN, M.; MEIRELLES, M. S. O. P.; DUBREUIL, V.; DURIEUX, L. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing**, v. 32, n. 22, p. 7847-7871, 2011.

BARBOSA, H. A. **Análise espaço temporal de índice de vegetação AVHRR/NOAA e precipitação na região nordeste do Brasil em 1982-85**. 170 p. (INPE-7237-TDI/690). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998.

BARBOSA, S.E.S. **Análise de dados hidrológicos e regionalização de vazões da bacia do rio do Carmo**. 211 f. 2004. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Federal de Ouro Preto, Ouro Preto, 2004. Disponível em: https://www.repositorio.ufop.br/bitstream/123456789/3146/1/DISSERTA%c3%87%c3%83O_An%c3%a1liseDadosHidrol%c3%b3gicos.pdf. Acesso em: 05 mar. 2020.

BAYMA, A.P. **Análise do potencial de séries temporais de índices de vegetação (NDVI e EVI) do sensor MODIS para detecção de desmatamentos no bioma cerrado**. 2015. 99 p. Dissertação (Mestrado em Geociências Aplicadas) - Universidade de Brasília (UNB), Brasília, 2015.

BENDINI, H. N. **Agricultural land classification based on phenological information from dense time-series Landsat-like images in the Brazilian Cerrado**. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2018. Disponível em: <http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2018/08.07.16.22/doc/publicacao.pdf>. Acesso em: 28 fev. 2019.

BENDINI, H. N. ; FONSECA, L. M. G.; KÖRTING, T. S.; SANCHES, I. D. A.; MARUJO, R. Evaluation of smoothing methods on Landsat-8 EVI time series for crop classification based on phenological parameters. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos-SP. **Anais...** São José dos Campos, SP: INPE,, 2017. p. 4267 – 4274.

BORGES, E. F. **Discriminação das fitofisionomias de cerrado do oeste baiano por meio de dados multiangulares de sensoriamento remoto.** 2014. 136 p. Tese (Doutorado em Geociências Aplicadas) - Universidade de Brasília (UNB), Brasília, 2014.

BORGES, E. F.; SANO, E. E.; MEDRADO, E. Radiometric quality and performance of TIMESAT for smoothing moderate resolution imaging spectroradiometer enhanced vegetation index time series from western Bahia State, Brazil. **Journal of Applied Remote Sensing**, v.8, 083580-1-21, 2014.

BREIMAN, L.; FREADMAN, J.; OLSHEN, R.; STONE, C. **Classification and regression trees.** [S.l.]: Wadsworth, 1984.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting.** 2.ed. New York: Springer-Verlag, 2002. 434p.

CARVALHO JÚNIOR, O. A.; SAMPAIO, C. S.; SILVA, N. C.; COUTO JÚNIOR, A. F.; GOMES, R. A. T.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. Classificação de padrões de savana usando assinaturas temporais NDVI do sensor MODIS no Parque Nacional da Chapada dos Veadeiros. **Revista Brasileira de Geofísica**, v. 26, n. 4, p. 505-517, 2008.

CARVALHO, M. S.; MOREIRA, R. M.; RIBEIRO, K. D.; ALMEIDA, A. M. Concentração de metais no rio Doce em Mariana, Minas Gerais, Brasil. **Acta Brasiliensis**, v. 1, n. 3, p. 37-41, 2017. Disponível em: <http://revistas.ufcg.edu.br/ActaBra/index.php/actabra/article/view/58>. Acesso em: 01 fev. 2019.

CHEN, W.; XIE, X.; WANG, J.; PRADHAN, B.; HONG, H.; BUI, D.T.; DUAN, Z.; MA, J. A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. **Catena**, v. 151, p. 147-160, 2017. DOI: <https://doi.org/10.1016/j.catena.2016.11.032>.

CHU, L.; WANG, L. J.; JIANG, J.; LIU, X. Comparison of landslide susceptibility maps using random forest and multivariate adaptive regression spline models in combination with catchment map units. **Geosciences Journal**, v. 23, n. 2, p. 341-355, 2018.

COMPANHIA DE PESQUISA DE RECURSOS MINERAIS (CPRM). **Mapa Geológico do Estado de Minas Gerais:** escala 1:1.000.000. 2014. Disponível: <<http://geosgb.cprm.gov.br/>>. Acesso em: 13 fev. 2020.

COMPANHIA DE PESQUISA DE RECURSOS MINERAIS (CPRM). **Gerenciamento integrado da Bacia do Rio Doce:** diagnóstico, plano diretor, simulação financeira. Brasília: Ministério das Minas e Energia, 1993. 254p.

CONSELHO NACIONAL DOS DIREITOS HUMANOS (CNDH). **Relatório da Missão Emergencial a Brumadinho/MG após rompimento da Barragem do Vale S/A.** Brasília-DF: CNDH, 2019. 27p. Disponível em: <https://www.mdh.gov.br/todas-as-noticias/2019/fevereiro/missao-emergencial-do-cndh-apresenta-relatorio-sobre-rompimento-de-barragem-davale/RelatrioMissoemergencialaBrumadinho.pdf>. Acesso em: 20 fev. 2019.

COUTINHO, A. C.; ESQUERDO, J. C. D. M.; OLIVEIRA, L. S.; LANZA, D. A. Methodology for systematical mapping of annual crops in Mato Grosso do Sul State (Brazil). **Geografia**, Rio Claro, v. 38, n. Esp., p. 45-54, 2013.

COUTO JUNIOR, A. F.; CARVALHO JUNIOR, O. A.; MARTINS, E. S. Séries temporais MODIS aplicadas em sucessão de culturas de soja (*Glycine max* (L.) Merrill) e milho (*Zea mays* L.) em sistema de plantio direto. **Revista Brasileira de Cartografia**, v. 64, n. 3, p. 405-418, 2012. Disponível em: <<http://www.lsie.unb.br/rbc/index.php/rbc/article/view/423>>. Acesso em: 6 maio 2014.

CORRÊA, T. L. **Bioacumulação de metais pesados em plantas a partir de suas disponibilidades em rochas e sedimentos: o efeito na cadeia trófica.** 2006. 157p. Dissertação (Mestrado em Evolução Crustal e Recursos Naturais) - Departamento de Geologia, Universidade Federal de Ouro Preto, Ouro Preto, MG, 2006.

DEFESA CIVIL. **Codificação Brasileira de Desastres.** 2019. Disponível em: <https://www.mdr.gov.br/protecao-e-defesa-civil/centro-nacional-de-gerenciamento-de-riscos-e-desastres-cenad/entenda-os-desastres>. Acesso em: 10 jan. 2019.

EARTH ENGINE DATA CATALOG. **Datasets.** 2018. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LE07_C01_T1_SR>. Acesso em: 10 jan. 2019.

EMERGENCY DATABASE (EM-DAT). **The office of foreign disaster assistance/Centre for Research on the Epidemiology of Disasters.** Brussels, Belgium: Université Catholique de Louvain. Disponível em: <<https://www.emdat.be/>>. Acesso em: 02 fev. 2020.

EMPRESA DE ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL (EMATER). **Zoneamento ambiental produtivo do conjunto de sub-bacias do baixo trecho do rio do Carmo.** Belo Horizonte–MG: Governo de Minas Gerais, 2017a. Disponível em: <<http://www.agricultura.mg.gov.br/index.php/cidadao/zoneamento-ambiental-produtivo>>. Acesso em: 20 jan. 2020.

EMPRESA DE ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL (EMATER). **Zoneamento ambiental produtivo da bacia hidrográfica do rio Gualaxo do Norte**. Belo Horizonte–MG: Governo de Minas Gerais, 2017b. Disponível em: <<http://www.agricultura.mg.gov.br/index.php/cidadao/zoneamento-ambiental-produtivo>>. Acesso em: 20 jan. 2020.

EMPRESA DE ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL (EMATER). **Zoneamento ambiental produtivo do conjunto de sub-bacias hidrográficas do alto e médio baixo do rio do Carmo**. Belo Horizonte–MG: Governo de Minas Gerais, 2018. Disponível em: <<http://www.agricultura.mg.gov.br/index.php/cidadao/zoneamento-ambiental-produtivo>>. Acesso em: 20 jan. 2020.

EUROPEAN SPACE AGENCY (ESA). **Technical guides**. 2000-2020. Disponível em: <<https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm>>. Acesso em: 05 dez. 2019.

EVA, H.; LAMBIN, E. F. Remote sensing of biomass burning in tropical regions: sampling issues and multisensor approach. **Remote Sensing of Environment**, v. 64, p. 292-315, 1998.

FARIA, M. M. **Candeia (Eremanthus sp.) especialização e interações ambientais no município de Mariana (MG)**. 2012. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa MG, 2012.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v.17, n.3, p.37-54, 1996.

FOLEY, J. A.; DEFRIES, R.; ASNER, G. P.; BARFORD, C.; BONAN, G.; CARPENTER, S. R.; CHAPIN, F. S.; COE, M. T.; DAILY, G. C.; GIBBS, H. K.; HELKOW, J. H.; HOLLOWAY, T.; HOWARD, E. A.; KUCHARIK, C. J.; MONFREDA, C.; PATZ, J. A.; PRENTICE, C.; RAMANKUTTY, N.; SNYDER, P. K. Global consequences of land use. **Science**, v. 309, n. 5734, p.570-574, 2005. Disponível em: <http://www.sciencemag.org>. Acesso em: 01 fev. 2019.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, p. 185-201, 2002.

FORMIGONI, M. d. H.; XAVIER, A. C.; LIMA, J. S. D. S. Análise temporal da vegetação na região do nordeste através de dados evi do modis. **Ciência Florestal**, v. 21, n. 1, p. 1–8, 2011.

FUNDAÇÃO ESTADUAL DO MEIO AMBIENTE (FEAM). **Inventário de barragem do Estado de Minas Gerais: ano 2017**. Belo Horizonte-MG: FEAM, 2018. 40p. Disponível em:

http://www.feam.br/images/stories/2018/BARRAGENS/Invent%C3%A1rio_de_Barragens_2017.pdf. Acesso em: 20 fev. 2019.

FUNDAÇÃO RENOVA. **Relato de atividades 2016**. 2016. 69p. Disponível em: <<https://www.fundacaorenova.org/relato-de-atividades/sobre-o-relato/>>. Acesso em: 18 fev. 2019.

GAIAD, N. P.; MARTINS, A.P.M.; DEBASTIANI, A.B.; CORTE, A.P.D.; SANQUETTA, C.R. Uso e cobertura da terra apoiados em algoritmos baseados em aprendizado de máquina: o caso de Mariana–MG. **Enciclopédia Biosfera**, v. 14, n. 25, p. 1211-1220, 2017.

GIROLAMO NETO, C. D.; FONSECA, L. M. G.; KORTING, T. S.; SANCHES, I. D. A.; EBERHARDT, I. D. R.; BENDINI, H. N.; MARUJO, R. F. B.; TRABAQUINI, K. Classificação automática de áreas cafeeiras utilizando imagens de sensoriamento remoto e técnicas de mineração de dados. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 1609-1616. Internet. ISBN 978-85-17-0076-8. IBI: <8JMKD3MGP6W34M/3JM495M>. Disponível em: <<http://urlib.net/rep/8JMKD3MGP6W34M/3JM495M>>.

GIROLAMO NETO, C. D. **Identificação de fitofisionomias de Cerrado no Parque Nacional de Brasília utilizando random forest aplicado a imagens de alta e média resoluções espaciais**. 2018. 186 p. IBI: <8JMKD3MGP3W34R/3RU6Q68>. (sid.inpe.br/mtc-m21c/2018/10.03.18.55-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2018. Disponível em: <<http://urlib.net/rep/8JMKD3MGP3W34R/3RU6Q68>>.

GOLDSCHMIDT, R.; PASSOS, E. **Data mining**: um guia prático. Rio de Janeiro: Elsevier, 2005. 257 p.

GOOGLE. **Google Earth Engine**. 2015. Disponível em: <https://earthengine.google.com/>. Acesso em: 03 mar. 2019.

GRUPO DA FORÇA TAREFA. **Força-tarefa Barragem de fundão Mariana - MG (decreto nº 46.892/15)**. 2016. Disponível em: <http://www.meioambiente.mg.gov.br/images/stories/2016/DESASTRE_MARIANA/Relat%C3%B3rios/Relatorio_final.pdf>. Acesso em: 02 fev. 2020.

HAMUNA, B.; KALOR, J. D.; TABLASERAY, V. E. The impact of tsunami on mangrove spatial change in eastern coastal of Biak Island, Indonesia. **Journal of Ecological Engineering**, v. 20, n. 3, p. 1-6, 2019.

HAN, J.; KAMBER, M.; PEI, J. **Data mining**: concepts and techniques. 3.ed. San Francisco: Morgan Kaufmann, 2011.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n.Spec, p. 195-213, 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, n.3, p. 295-309, 1988.

INSTITUTO BRASILEIRO DE MEIO AMBIENTE E RECURSOS NATUAIS RENOVÁVEIS (IBAMA). **Laudo técnico preliminar: impactos ambientais decorrentes do desastre envolvendo o rompimento da barragem de Fundão, em Mariana, Minas Gerais.** Brasília: IBAMA, 2005. 38 p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Série manuais técnicos em geociências: número 1, manual técnico da vegetação brasileira.** 1992. Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/monografias/GEBIS%20-%20RJ/ManuaisdeGeociencias/Manual%20Tecnico%20da%20Vegetacao%20Brasileira%20n.1.pdf>> Acesso em: 28 jan. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **EMBRAPA: mapa de solos do Brasil.** Rio de Janeiro: IBGE, 2001. Disponível em: <http://www.dpi.inpe.br/Ambdata/mapa_solos.php> Acesso em: 28 jan. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Mapa de vegetação do Brasil, escala 1:5. 000.000.** Rio de Janeiro. 2006. Disponível em: <ftp://geoftp.ibge.gov.br/informacoes_ambientais/vegetacao/mapas/brasil/vegetacao.pdf>. Acesso em: 05 Jan. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Atlas dos remanescentes florestais da Mata Atlântica no período de 2013-2014.** São Paulo: Fundação S.OS. Mata Atlântica; São José dos Campos: INPE, 2015.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Atlas dos remanescentes florestais da Mata Atlântica no período de 2014-2015.** São Paulo: Fundação S.OS. Mata Atlântica; São José dos Campos: INPE, 2016.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Atlas dos remanescentes florestais da Mata Atlântica no período de 2015-2016.** São Paulo: Fundação S.OS. Mata Atlântica; São José dos Campos: INPE, 2017.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Atlas dos remanescentes florestais da Mata Atlântica no período de 2016-2017.** São Paulo: Fundação S.OS. Mata Atlântica; São José dos Campos: INPE, 2018.

JACKSON, R.D.; HUETE, A.R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, Amsterdam, v. 11, n. 3, p. 185-200, 1991.

JACQUIN, A.; SHEEREN, D.; LACOMBE, J. P. Vegetation cover degradation assessment in Madagascar savanna based on trend analysis of MODIS NDVI time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 125, p. S3-S10, 2010.

JÖNSSON, P.; EKLUNDH, L. Seasonality extraction by function fitting to time-series of satellite sensor data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 8, p. 1824-1832, 2002. DOI: 10.1109/TGRS.2002.802519.

JÖNSSON, P., EKLUNDH, L. TIMESAT - a program for analyzing time-series of satellite sensor data. **Computing Geoscience**, v. 30, p. 833 – 845, 2004.

JÖNSSON, P.; EKLUNDH, L. **TIMESAT 3.2 with parallel processing software manual**. Lund, Sweden: Lund University, 2015. 88p. Disponível em: <http://web.nateko.lu.se/timesat/docs/TIMESAT32_software_manual.pdf>. Acesso em: 13 fev. 2020.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOSMODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, p.261-270, 1992.

KIM, J. C.; LEE, S.; JUNG, H.S.; LEE, S. Landslide susceptibility mapping using random forest and boosted tree models in Pyeong-Chang, Korea. **Geocarto international**, v. 33, n. 9, p. 1000-1015, 2018. DOI: 10.1080/10106049.2017.1323964.

KORTING, T. S. **GeoDMA**: a toolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery. 2012. 119 p. IBI: <8JMKD3MGP7W/3CCH86S>. (sid.inpe.br/mtc-m19/2012/07.31.18.22-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/rep/8JMKD3MGP7W/3CCH86S>>.

LHERMITTE, S.; VERBESSELT, J.; VERSTRAETEN, W.W.; COPPIN, P. A comparison of time series similarity measures for classification and change detection of ecosystem dynamics. **Remote Sensing of Environment**, v. 115. p. 3129-3152, 2011.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande, MS: UNIDERP, 2007. 908 p. ISBN 85-7704-040-0.

LOPES, L. M. N. O rompimento da barragem de Mariana e seus impactos socioambientais. **Sinapse Múltipla**, v. 5, n. 1, p. 1-14, 2016.

MACHADO, M. F.; SILVA, S. F. **Geodiversidade do estado de Minas Gerais**. Belo Horizonte: CPRM, 2010. 136p. Disponível em: <<http://rigeo.cprm.gov.br/xmlui/handle/doc/16735>>. Acesso em: 11 jan. 2020.

MARCELINO, E. V. (Ed.). **Desastres naturais e geotecnologias: conceitos básicos**. Santa Maria, RS: [s.n.] 2008. 40 p. (INPE-15208-PUD/193).

MAUS, V. W. Satellite time series analysis for land use/cover change detection. In: YSSP LATE SUMMER WORKSHOP, 2013, Laxenburg. **Proceedings...** Laxenburg: International Institute for Applied Systems Analysis, 2013. v. 1. p. 8.

MELAAS, E.K.; FRIEDL, M. A.; ZHU, Z.; Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM+ data. **Remote Sensing of Environment**, v. 132, p. 176-185, 2013.

MIELKE, C.; BOESCHE, N. K.; ROGASS, C.; KAUFMANN, H., GAUERT, C.; WIT, M. Spaceborne mine waste mineralogy monitoring in South Africa, applications for modern push-broom missions: Hyperion/OLI and EnMAP/Sentinel-2. **International Journal of Remote Sensing**, n. 6, p. 6790-6816, 2014.

MOREIRA, M. A. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa-MG: UFV, 2011. 422 p. ISBN 978-85-7269-381-3.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2.ed. São Paulo-SP: Edgard Blucher, 2006. 538 p. ISBN 978-85-212-0389-6.

MULLER, H.; RUFIN, P.; GRIFFITHS, P.; SIQUEIRA, A. J. B.; HOSTERT, P. Mining dense Landsat time-series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. **Remote Sensing of Environment**, v. 156, p. 490-499, 2015.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4 ed. São José dos Campos, SP: Blucher, 2010. 388 p.

OLOFSSON, P.; FOODY, G.M.; HEROLD, M.; STEHMAN, S.V.; WOODCOCK, C. E.; WULDER, M. A. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing**, v. 148, p. 42-57, 2014. DOI: <10.1016/j.rse.2014.02.015>.

OSHIRO, T. M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica**. 2013. 90f. Dissertação (Mestrado em Bioinformática) - Universidade de São Paulo, Ribeirão Preto, 2013.

PADOVANI, C. R. **Dinâmica espaço-temporal das inundações do Pantanal**. 2010. 175 f. Tese (Doutorado em Ecologia Aplicada) - Universidade de São Paulo, Piracicaba, 2010.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825 – 2830, 2011.

PEDROSA, L. **Reavaliação do sistema de classificação de barragens realizado pelo DNPM**. 2017, 148 f. Dissertação (Mestrado em Engenharia Geotécnica) - Universidade Federal de Ouro Preto, Ouro Preto MG, 2017.

PEÑA, M. A.; ULLOA, J. Mapping the post-fire vegetation recovery by NDVI time series. In: INTERNACIONAL SYMPOSIUM OF GEOSCIENCE AND REMOTE SENSING (GRSS-CHILE), 1., 2017. **Proceedings...** IEEE, 2017. p. 1-8.

PETITJEAN, F.; INGLADA, J.; GANÇARSKI, P. Satellite image time series analysis under time warping. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 8, p. 3081-3095, 2012.

PLANO INTEGRADO DE RECURSOS HÍDRICOS DA BACIA DO RIO DOCE (PIRH). **Plano de ação de recursos hídricos da unidade de planejamento e gestão dos recursos hídricos Piranga - PARH Piranga**. 2010. Disponível em: <http://www.cbhdoce.org.br/wp-content/uploads/2016/12/PARH_Piranga.pdf>. Acesso em: 07 fev. 2020.

PONZONI, F. J.; SHIMABUKURU, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**, 2. ed. São Paulo, SP: Oficina de Textos, 2012. 160 p. ISBN 978-85-7975-053-3.

PROJETO MAPBIOMAS. **Coleção revisada dos mapas anuais mapas de cobertura e uso do solo do Brasil de 1985 até 2018**. 2019 Disponível em: <https://plataforma.mapbiomas.org/map#coverage>. Acesso em: 17 out. 2019.

PROJETO RADAMBRASIL. MINISTÉRIO DAS MINAS E ENERGIA.. **Folhas SF.23/24 Rio de Janeiro / Vitória**: levantamento de recursos naturais. Rio de Janeiro: Radam, 1983., v.32.

PROUS, A. **Arquivos do Museu de História Natural e Jardim Botânico** v. 24, n. 1, 2015. ISSN 2525-6084. Disponível em: <<https://www.ufmg.br/mhnpj/publicacoes/mhnpj/arquivos-do-museu/>>. Acesso em 03 mar. 2020.

RAMANKUTTY, N.; FOLEY, J. A. Estimating historical changes in global land cover: Croplands from 1700 to 1992. **Global Biogeochemical Cycles**, v. 13, n. 4, p. 997-1027, 1999.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, p. 1541-52, 1977.

ROESER, H. M. P.; ROESER, P. A. O Quadrilátero ferrífero - MG, Brasil: aspectos sobre sua história, seus recursos minerais e problemas ambientais relacionados. **Revista Geonomos**, v. 18, n. 1, p. 33-37, 2010.

RONAGHAN, S. **The mathematics of decision trees, random forest and feature importance in scikit-learn and spark**. 2018. Disponível em: <<https://towardsdatascience.com/the-mathematics-of-decision-trees-random-forest-and-feature-importance-in-scikit-learn-and-spark-f2861df67e3>>. Acesso em: 20 jun. 2019.

ROSIM, S.; OLIVEIRA, J. R. F.; JARDIM, A. C.; NAMIKAWA, L. M.; RENNÓ, C. D. TerraHidro: A distributed hydrology modelling system with high quality drainage extraction. In: INTERNATIONAL CONFERENCE ON ADVANCED GEOGRAPHIC INFORMATION SYSTEMS, APPLICATIONS, AND SERVICES, 5., 2013, Nice. **Proceedings...** 2013. p. 161-167. Disponível em: <http://www.thinkmind.org/index.php?view=article&articleid=geoprocessing_2013_7_20_30125>. Acesso em: 20 jul. 2019.

ROUSE JUNIOR, J. W.; HAAS, R. H.; DEERING, D. W.; SCHELL, J. A.; HARLAN, J. C. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Greenbelt: NASA, 1974.

RUBEL, F.; KOTTEK, M. Observed and projected climate shifts 1901-2100 depicted by world maps of the Köppen-Geiger climate classification. **Meteorologische Zeitschrift**, v.19, p. 135-141, 2010. DOI: 10. 1127/0941-2948/2010/0430.

RUDORFF, B. F. T.; ADAMI, M.; AGUIAR, D. A.; GUSSO, A.; SILVA, W. F. da; FREITAS, R. M. Temporal series of evi/modis to identify land converted to sugarcane. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 6., 2009, Cape Town, South Africa. **Proceedings...** Cape Town: IEEE, 2009. p. 252–255. ISBN 978-1-4244-3394-0.

SAKAMOTO, T.; YOKOZAWA, M.; TORITANI, T.; SHIBAYAMA, M.; ISHITSUKA, N.; OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, v. 96, n. 3/4, p. 366-374, 2005.

SHIMABUKURO, Y. E.; SANTOS, J. R.; NOVO, E. M. L. M.; KRUG, T.; HESS, L. **Estimativa da área de cobertura florestal afetada pelo incêndio em Roraima, utilizando dados multi-sensores**. Sao Jose dos Campos: INPE, 1999. 77 p. IBI: <[6qtX3pFwXQZ3r59YD6/GNU2P](http://urlib.net/rep/6qtX3pFwXQZ3r59YD6/GNU2P)>. (INPE-7119-RPQ/697). Disponível em: <<http://urlib.net/rep/6qtX3pFwXQZ3r59YD6/GNU2P>>.

SILVA, G. F.; CARVALHO, M. V. A.; CRUZ, C. B. M. Análise espaço-temporal do desastre ambiental em Mariana-MG a partir das geotecnologias. **Revista Continentes**, n. 13, p. 49-67, 2019.

SILVA, J. R.; SIQUEIRA, L. Avaliação temporal da variação de cobertura de solo através da utilização de índices de vegetação normalizado (NDVI) e ajustado ao solo (SAVI): caso de estudo para o Rio Doce e o Desastre Ambiental de Mariana. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 27.; EXPOCART, 26., 2017, Rio de Janeiro. **Anais...** Rio de Janeiro-RJ: SBC, 2017. p. 739-743.

SILVA JÚNIOR, C. A.; COUTINHO, A. D.; OLIVEIRA-JÚNIOR, J. F.; TEODORO, P. E.; LIMA, M.; SHAKIR, M.; GOIS, G.; JOHANN, J. A. Analysis of the impact on vegetation caused by abrupt deforestation via orbital sensor in the environmental disaster of Mariana, Brazil. **Land use policy**, v. 76, p. 10-20, Jul. 2018.

SILVA, M. A. O.; ANDRADE, A. C. Geração de Imagens de Reflectância no Topo da Atmosfera e na Superfície de um Ponto de Vista Geométrico. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 8238-8245. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). IBI: <3ERPFQRTRW34M/3E7GCG4>. Disponível em: <<http://urlib.net/rep/3ERPFQRTRW34M/3E7GCG4>>.

SILVEIRA, E. M. O.; ACERBI JÚNIOR, F. W.; MELLO, J. M.; BUENO, I. T. Object-based change detection using semivariogram indices derived from NDVI images: the environmental disaster in Mariana, Brazil. **Ciência e Agrotecnologia**, v. 41, p. 554-564, 2017. Disponível em: https://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-70542017000500554. Acesso em: 05 fev. 2019.

SISTEMA DE MEIO AMBIENTE DO ESTADO DE MINAS GERAIS (SISEMA). **Relatório operação WATU**: fase 1. fiscalização dos trechos prioritários de recuperação atingidos pelos rejeitos da barragem de Fundão. 2016. Disponível em: <http://www.ief.mg.gov.br/images/stories/2016/RELAT%C3%93RIO_FINAL_WATU-FASE_I.pdf>. Acesso em: 13 fev. 2020.

SISTEMA DE MEIO AMBIENTE DO ESTADO DE MINAS GERAIS (SISEMA). **Relatório operação WATU**: fase V. fiscalização dos trechos prioritários de recuperação atingidos pelos rejeitos da barragem de Fundão. 2018. Disponível em: <http://www.meioambiente.mg.gov.br/images/stories/2020/WATU/OPERA%C3%87%C3%83O_WATU_-_Fase_IX_290420.pdf>. Acesso em: 13 fev. 2020.

SISTEMA DE MEIO AMBIENTE DO ESTADO DE MINAS GERAIS (SISEMA). **Relatório operação WATU**:- fase IX. fiscalização dos trechos prioritários de recuperação atingidos pelos rejeitos da barragem de Fundão. 2020. Disponível

em: <http://www.meioambiente.mg.gov.br/images/stories/2020/WATU/OPERA%C3%87%C3%83O_WATU_-_Fase_IX_290420.pdf>. Acesso em: 13 fev. 2020.

SOARES, A. R. ; BENDINI, H. N.; VAZ, D. V.; UEHARA, T. D. T.; NEVES, A. K.; LECHLER, S.; KORTING, T. S.; FONSECA, L. M. G. STMETRICS: a Python package for satellite image time-series feature extraction. In: 2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. **Proceedings...** 2020. No prelo.

SOBRAL, A. P. B. **Previsão de carga horária – uma nova abordagem por árvore de decisão**. 2003. 56 f. Tese (Doutorado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2003.

SOS MATA ATLÂNTICA; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE).. **Análise do impacto sobre áreas de Mata Atlântica do rompimento da barragem localizada no subdistrito de Bento Rodrigues, no município de Mariana-MG**. 2015. Disponível em: https://www.dropbox.com/s/blpifrcox1bpg3e/091215_AtlasRioDoce_Relatorio_final.pdf?dl=0. Acesso em: 02 fev. 2019.

SOUDANI, K.; HMIMINA, G.; DELPIERRE, N.; PONTAILLER, J. Y.; AUBINET, M.; BONAL, D.; CAQUET, B.; GRANDCOURT, A.; BURBAN, B.; FLECHARD, C.; GUYON, D.; GRANIER, A.; GROSS, P.; HEINESH, B.; LONGDOZ, B.; LOUSTAU, D.; MOUREAUX, C.; OURCIVAL, J. M.; RAMBAL, S.; SAINT ANDRÉ, L.; DUFRÊNE, E. Ground-based Network of NDVI measurements for tracking temporal dynamics of canopy structure and vegetation phenology in different biomes. **Remote Sensing of Environment**, v. 123, p. 234-245, 2012.

TAALAB, K.; CHENG, T.; ZHANG, Y. Mapping landslide susceptibility and types using Random Forest. **Big Earth Data**, v. 2, n. 2, p. 159-178, 2018. DOI: 10.1080/20964471.2018.1472392.

TAFURI, A. C. **Valoração ambiental do Parque Estadual do Itacolomi, Ouro Preto, Minas Gerais**. 2008. 159 f. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) - Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

TAN, B.; MORISETTE, J. T.; WOLFE, R. E.; GAO, F.; EDERER, G. A.; NIGHTINGALE, J.; PEDELTY, J. A. An enhanced TIMESAT algorithm for estimating vegetation phenology metrics from MODIS data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 4, n. 2, p. 361-371, 2011.

TELES, T. S. **Relações de métricas fenológicas EVI/MODIS do TIMESAT com sombreamento e padrões atípicos de temperatura em floresta estacional decidual**. 2015. 112 p. IBI: <8JMKD3MGP3W34P/3J3G3LP>. (sid.inpe.br/mtc-m21b/2015/02.27.14.14-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE),

São José dos Campos, 2015. Disponível em: <<http://urlib.net/rep/8JMKD3MGP3W34P/3J3G3LP>>. Acesso em: 06 fev. 2019.

UNITED STATES GEOLOGICAL SURVEY (USGS). **Remote sensing phenology revised metrics for 2003 – 2017 released**. 2019. DOI: <<https://doi.org/10.5066/F7PC30G1>>. Disponível em: <<https://www.usgs.gov/center-news/remote-sensing-phenology-revised-metrics-2003-2017-released>> Acesso em: 10 fev. 2020.

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106-115, 2010b.

VERBESSELT, J.; HYNDMAN, R.; ZEILEIS, A.; CULVENOR, D. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, v.114, n. 12, p. 2970-2980, 2010a.

VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, v. 123, n. 0, p. 98 – 108, 2012.

VRIELING, A.; BEURS, K. M.; BROWN, M. E. Variability of African farming systems from phenological analysis of NDVI time series. **Climatic Change**, v. 109, p. 455-477, 2011.

WARDLOW, B. D.; EGBERT, S.L.; KASTENS; J. H. Analysis of time-series MODIS 250m vegetation index data for crop classification in the US central Great Plains. **Remote Sensing of Environment**, v. 108, p. 290-310, 2007.

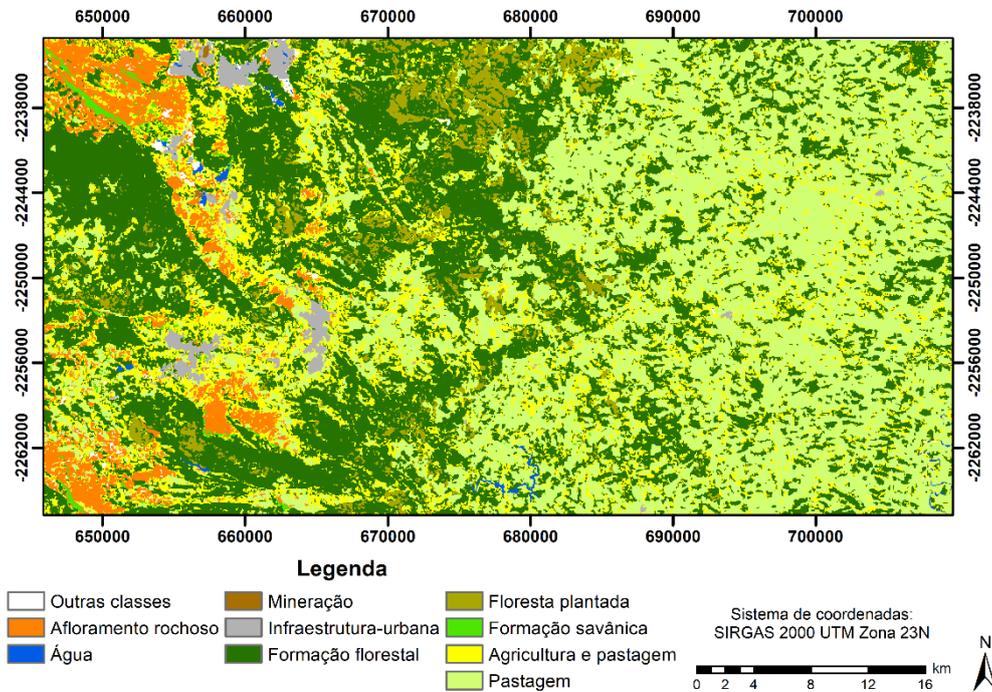
WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: practical machine learning tools and techniques**. San Francisco: Morgan Kaufmann, 2011. 630 p.

WOODCOCK, C. E.; ALLEN, R.; ANDERSON, M.; BELWARD, A.; BINDSCHADLER, R.; COHEN, W.; GAO, F.; GOWARD, S. N.; HELDER, D.; HELMER, E.; NEMANI, R. Free access to Landsat imagery. **Science**, v. 320, n. 1011, 2008.

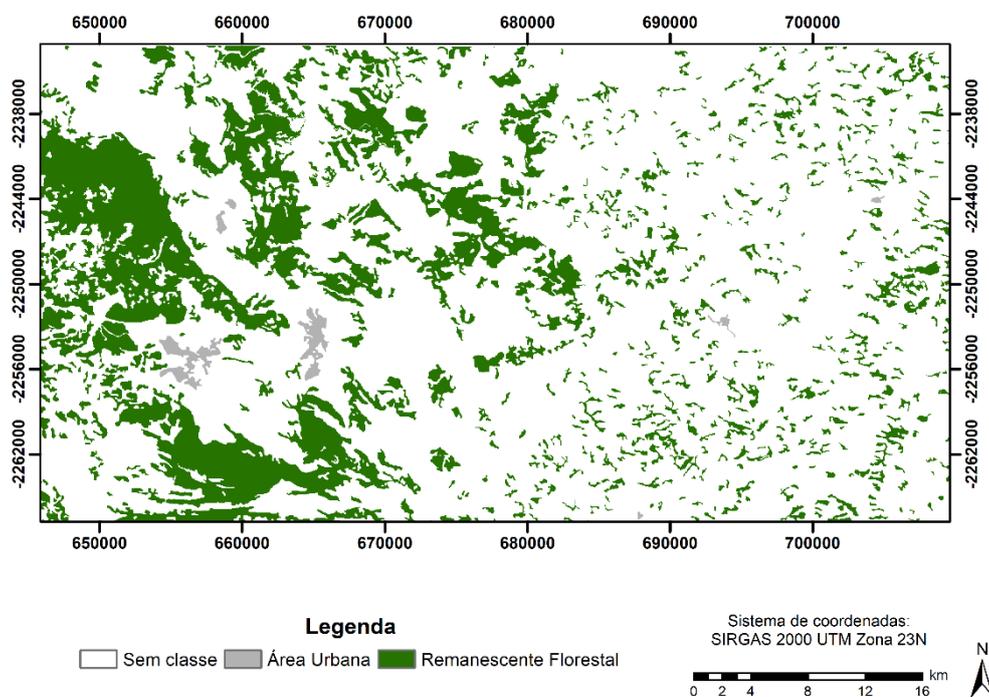
ZHANG, X.; FRIEDL, M. A.; SCHAAF, C. B.; STRAHLER, A. H.; HODGES, J. C. F.; GAO, F.; REED, B. C.; HUETE, A. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, v.84, n.3, p.471–475, 2003. DOI:10.1016/s0034-4257(02)00135-9.

APÊNDICE A – MAPAS UTILIZADOS PARA A VALIDAÇÃO DA CLASSIFICAÇÃO PRÉ-DESASTRE

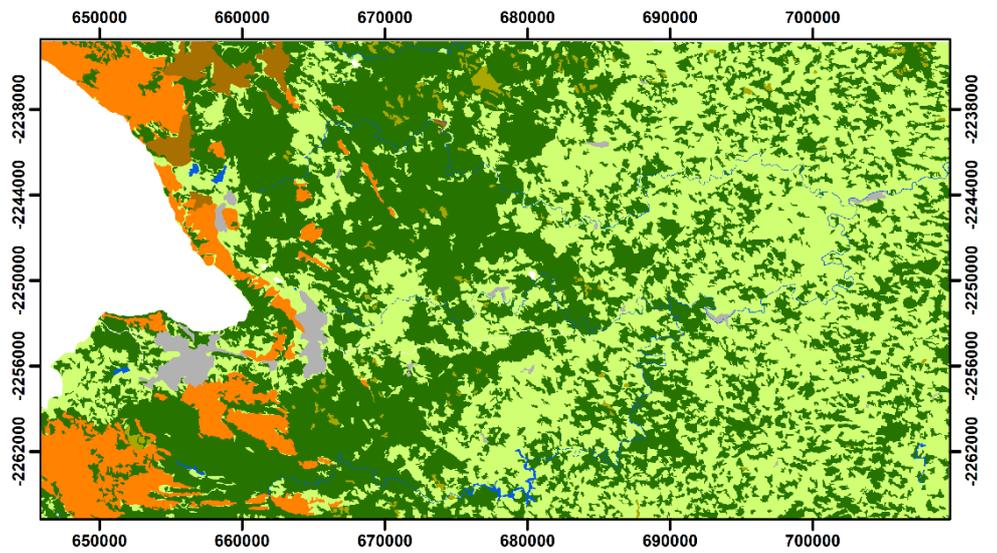
Mapa de uso e cobertura da terra - MapBiomos (2014)



Mapa de remanescentes florestais - SOS Mata Atlântica (2014)



Mapa de uso e cobertura da terra - ANA (2013/2014)



ana2.tif

Sem classe	Água	Vegetação nativa
Afloramento rochoso	Mineração	Reflorestamento
Área urbana	Pastagem	

Sistema de coordenadas:
SIRGAS 2000 UTM Zona 23N

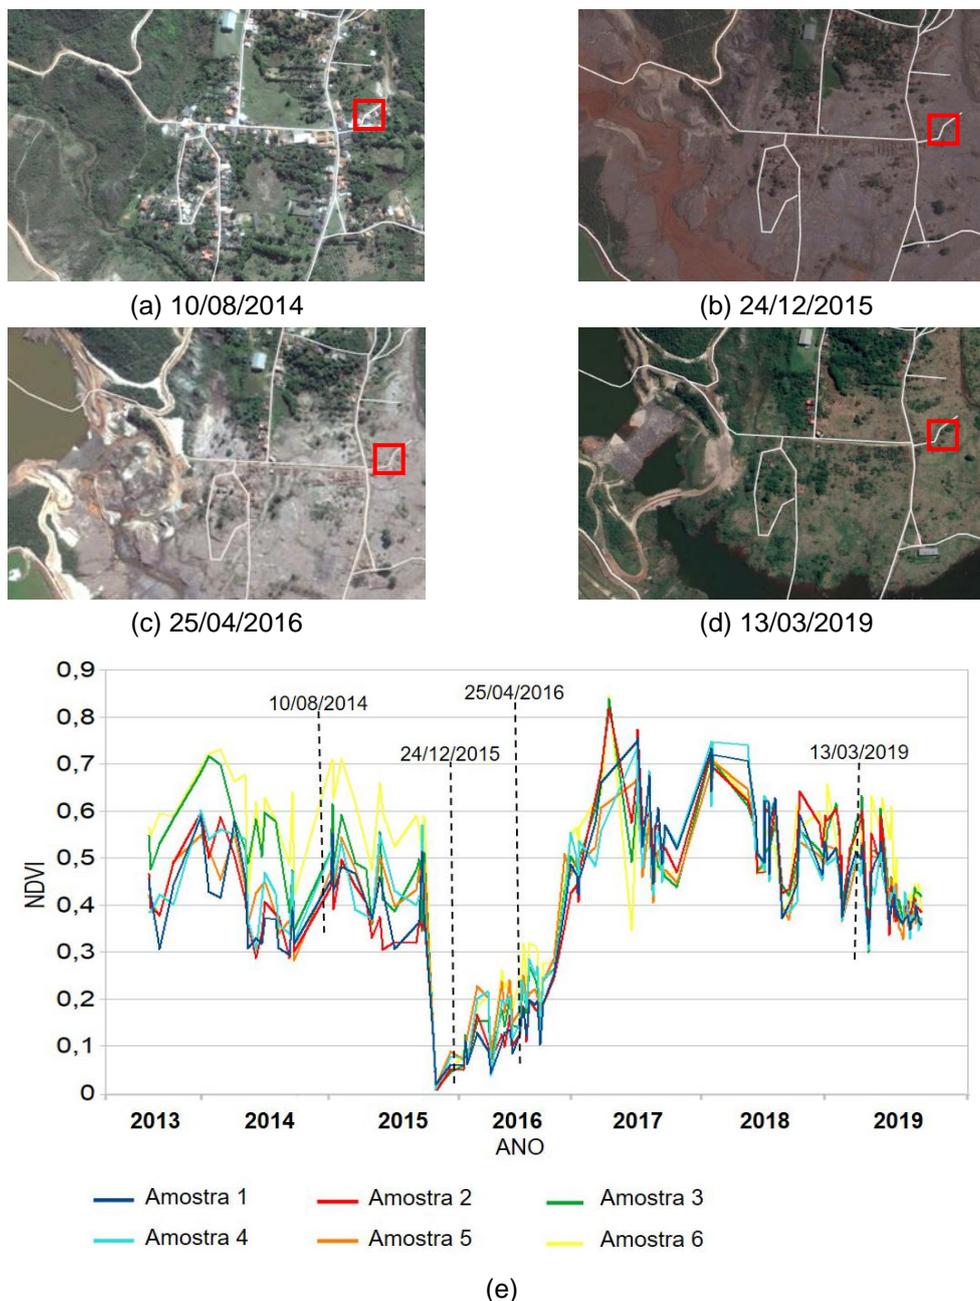
0 2 4 8 12 16 km

APÊNDICE B – COMPLEMENTO DE ANÁLISES DA COBERTURA DA TERRA CAUSADAS PELO DESASTRE DE MARIANA

A Figura B. 1 ilustra as principais mudanças observadas na área urbana de Bento Rodrigues e seis séries temporais de NDVI correspondentes à classe Área construída. Na Figura B. 1 são apresentadas imagens da área (a) antes do desastre (2014); (b) logo após o desastre (2015); (c) após a lama secar (2016); e, (d) anos após o desastre (2019). Estas análises foram aplicadas a fim de observar a dinâmica das áreas de vegetação afetadas pelo desastre, e o perfil de NDVI é apresentado na Figura B. 1 (e).

Embora seja difícil analisar áreas urbanas de menor porte na série temporal de NDVI, devido à resolução espacial das imagens, pode-se observar a redução dos valores de NDVI, indicativo dos impactos resultantes do desastre. Após a diminuição dos valores de NDVI causada pelo desastre, estes valores permaneceram em uma variação entre 0 e 0,3 durante um período de aproximadamente um ano, não apresentando indicações de retorno da vegetação. As curvas de NDVI mostram um aumento dos valores a partir de final de 2016, que seguem em aumentando nos primeiros meses de 2017 e se mantêm oscilando em valores mais altos próximos 0,55. A imagem apresentada em Figura B. 1 (d) ilustra um cenário mais atual desta região. Pode-se observar que a cobertura da área foi convertida para gramíneas e herbáceas.

Figura B. 1 – Imagens referentes à região de Bento Rodrigues e a série temporal de NDVI, a partir de amostras de áreas construídas.



As imagens acima, obtidas no Google Earth™, mostram diferentes cenários de mudança da cobertura da terra para a área urbana de Bento Rodrigues. Nessa figura são apresentadas imagens adquiridas (a) antes do desastre (2014); (b) logo após o desastre (2015); (c) após o depósito de lama secar (2016); e, (d) anos após o desastre (2019). A figura (e) apresenta seis perfis da série temporal de NDVI para a classe Área construída, referente a região apontada pelo quadrado em vermelho.

Fonte: Produção do autor.