



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

sid.inpe.br/mtc-m21c/2019/03.25.13.40-TDI

**MAPEAMENTO E MONITORAMENTO DA
COBERTURA VEGETAL DO ESTADO DA BAHIA
UTILIZANDO DADOS MULTITEMPORAIS DE
SENSORES ÓPTICOS ORBITAIS**

Andeise Cerqueira Dutra

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Yosio Edemir
Shimabukuro, e Egidio Arai,
aprovada em 29 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3T298T8>>

INPE
São José dos Campos
2019

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 INTELECTUAL DO INPE - CEPPII (PORTARIA N° 176/2018/SEI-INPE):**Presidente:**

Dr. 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, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/03.25.13.40-TDI

**MAPEAMENTO E MONITORAMENTO DA
COBERTURA VEGETAL DO ESTADO DA BAHIA
UTILIZANDO DADOS MULTITEMPORAIS DE
SENSORES ÓPTICOS ORBITAIS**

Andeise Cerqueira Dutra

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Yosio Edemir
Shimabukuro, e Egidio Arai,
aprovada em 29 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3T298T8>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Dutra, Andeise Cerqueira.

D953m Mapeamento e monitoramento da cobertura vegetal do estado da Bahia utilizando dados multitemporais de sensores ópticos orbitais / Andeise Cerqueira Dutra. – São José dos Campos : INPE, 2019.

xx + 119 p. ; (sid.inpe.br/mtc-m21c/2019/03.25.13.40-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

Orientadores : Drs. Yosio Edemir Shimabukuro, e Egidio Arai.

1. Modelo Linear de Mistura Espectral. 2. Moderate Resolution Imaging Spectroradiometer. 3. Random Forest. 4. Nordeste. 5. Bahia. I.Título.

CDU 528.8(813.8)



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/).

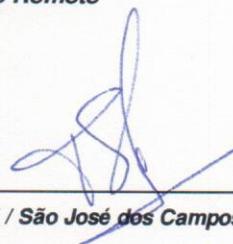
Aluno (a): **Andéise Cerqueira Dutra**

Título: "MAPEAMENTO E MONITORAMENTO DA COBERTURA VEGETAL DO ESTADO DA BAHIA UTILIZANDO DADOS MULTITEMPORAIS DE SENSORES ÓPTICOS ORBITAIS"

Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de **Mestre** em

Sensoriamento Remoto

Dr. Thales Sehn Körting

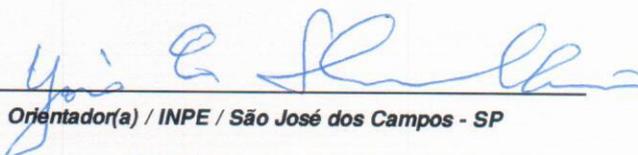


Presidente / INPE / São José dos Campos - SP

() Participação por Video - Conferência

Aprovado () Reprovado

Dr. Yosio Edemir Shimabukuro

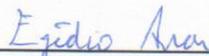


Orientador(a) / INPE / São José dos Campos - SP

() Participação por Video - Conferência

Aprovado () Reprovado

Dr. Egidio Arai

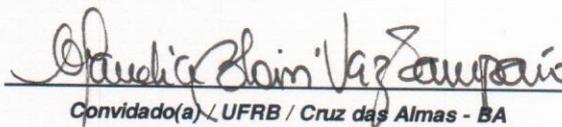


Orientador(a) / INPE / São José dos Campos - SP

() Participação por Video - Conferência

Aprovado () Reprovado

Dra. Cláudia Bloisi Vaz Sampaio



Convidado(a) / UFRB / Cruz das Almas - BA

() Participação por Video - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

*A Deus e à minha família,
dedico.*

AGRADECIMENTOS

Agradeço imensamente à minha família por todo apoio e encorajamento que me proporcionaram. Em especial aos meus pais, Floriano e Maria Cervellon, e ao meu irmão, Anderson, por sempre entregarem o melhor de si por mim, até mesmo durante toda minha ausência.

Ao programa de Pós-Graduação em Sensoriamento Remoto, principalmente ao meu Orientador Dr. Yosio Shimabukuro pelas grandes oportunidades, paciência, orientação, além do apoio e por sempre acreditar no meu esforço. Assim como ao meu Coorientador Dr. Egidio Arai, por todas as mensagens de apoio e grandes ensinamentos aplicados aos trabalhos e à vida.

Ao Victor Hugo Prudente e Denis Vieira, por me aturarem todos os dias em “nossa casinha”. Aos meus colegas e amigos da turma 2017, especialmente: Luciana Lima, Wesley Campanharo, Alana Neves, Willian Oliveira, Nildson Silva e o grupo “A vida é Fuzzy”, pelas risadas, companheirismo, aprendizado e horas de estudo. Como também nas boas conversas durante o almoço: Ana Carolina Santos, Aline Lopes, Juliana Diniz e Vinicius Pereira.

Aos amigos do INPE: Silvia Polizel, Leilane Passos, Bruno Montibeler, Alindomar Silva, Natália Wiederkehr, Lucas Oldoni e Daiane Vieira. Aos companheiros de sala: Kaio Gasparini e, em especial, Tânia Hoffmann por estar presente nos momentos mais difíceis e pela colaboração.

Aos docentes: Dra. Elisabete Moraes, Dr. Flávio Ponzoni, Dr. Camilo Rennó, Dr. Miguel Monteiro, Dra. Isabel Escada, Dr. Thales Körting, Dr. Lênio Galvão, Dra. Evlyn Novo, Dr. Cláudio Barbosa, Dr. Fábio Furlan, Dra. Leila Fonseca, Dr. Sidney Sant’Anna, Dr. Maurício Moreira, Dr. Luiz Aragão e Dra. Liana Anderson.

À Dra. Ieda Sanches pela paciência e orientação relacionadas à Pós-Graduação em Sensoriamento Remoto. E aos funcionários do Instituto Nacional de Pesquisas Espaciais.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pela bolsa concedida. A Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo financiamento dos projetos envolvidos e auxílios para os trabalhos de campo e eventos. A Universidade Estadual Paulista – Unesp, pela experiência em docência proporcionada, principalmente na figura da Dra. Klécia Gili Massi.

RESUMO

Conhecer a extensão e as taxas de degradação da terra para proteger os ecossistemas terrestres de um maior esgotamento, tem sido uma das questões mais importantes do nosso tempo. Entretanto, o Nordeste brasileiro tem sido negligenciado e pobremente estudado tanto em termos de programas de conservação quanto de investigação científica. Os produtos de Sensoriamento Remoto tornaram-se uma importante fonte de informações para monitorar as mudanças de cobertura da terra, no entanto, ainda é escasso o número de estudos para detectar e monitorar a vegetação de clima semiárido. Nesse contexto, o estado da Bahia foi selecionado para a realização desta pesquisa por possuir diversas formações vegetais e apresentar significativa mudança no uso e cobertura da terra. Devido à alta incidência de nuvens no estado, os produtos provenientes do sensor MODIS foram utilizados por apresentarem alta resolução temporal. Assim, esta pesquisa teve por objetivo propor uma abordagem de mapeamento e monitoramento do uso e cobertura da terra para o estado da Bahia utilizando dados multitemporais provenientes do sensor MODIS, abrangendo o período entre 2000 e 2017. Os objetivos específicos foram: a) estimar *endmembers* (*pixels* puros) a partir de imagens de melhor resolução espacial (30 m) do sensor OLI/Landsat 8 para posterior aplicação do Modelo Linear de Mistura Espectral (MLME) nos produtos provenientes do sensor MODIS (250 m); b) gerar uma série temporal de imagens fração derivadas do MLME entre 2000 e 2017 utilizando os *endmembers* estimados na fase anterior; c) gerar mosaicos das imagens fração calculando o valor máximo anual das proporções para os anos de 2000 e 2017; d) gerar dois mapas temáticos base de uso e cobertura da terra (LULC – *Land Use and Land Cover*) no estado da Bahia para os anos 2000 e 2017 utilizando os mosaicos gerados na fase anterior, aplicando o classificador *Random Forest*; e) avaliar as acurácias dos mapas de LULC obtidos; e f) analisar qualitativamente as séries temporais das imagens fração obtidas para todo o período analisado. Os resultados obtidos foram: 1) os *endmembers* estimados permitiram a melhoria dos resultados no que se refere ao erro, a variabilidade e a identificação das proporções dos componentes existentes nas imagens, visto a dificuldade na determinação dos *endmembers* e que a escolha indevida de *pixels* considerados como puros em produtos de baixa e moderada resolução espacial pode afetar a qualidade das imagens fração para uso operacional; 2) a abordagem utilizando as imagens fração contendo a proporção máxima anual dos componentes reduziu o volume de dados, ao mesmo tempo em que permitiu a separação das classes de LULC em função da associação entre as proporções de vegetação, solo e sombra, extraindo as características relacionadas aos padrões anuais das classes de LULC; 3) Os mapas de LULC para os anos de 2000 e 2017 obtiveram acurácias totais de 0,77 e 0,67, respectivamente, gerando a hipótese de que a seca severa que atingiu o Nordeste entre 2012 e 2017 influenciou o pior desempenho do classificador utilizado; 4) o uso de séries temporais das imagens fração permitiu o monitoramento das mudanças ocorridas na vegetação e também os impactos que podem estar associados aos eventos de seca. Assim, a abordagem aqui apresentada demonstra a potencialidade das imagens fração para a classificação e monitoramento semiautomático da cobertura vegetal a nível global e regional.

Palavras-chave: Modelo Linear de Mistura Espectral. *Moderate Resolution Imaging Spectroradiometer*. *Random Forest*. Nordeste. Bahia.

MAPPING AND MONITORING OF VEGETATION COVER IN THE BAHIA STATE USING MULTITEMPORAL DATA FROM OPTICAL ORBITAL SENSORS

ABSTRACT

Knowing the extent and rates of land degradation to protect terrestrial ecosystems from further depletion has been one of the most important issues of our time. However, the Brazilian Northeast has been neglected and poorly studied both in terms of conservation programs and scientific research. Remote Sensing products have become an important source of information for monitoring changes in land cover, however, there are still few studies to detect and monitor semi-arid vegetation. In this context, the state of Bahia was selected to carry out this research because it has diverse vegetation formations and presents a significant change in land use and land cover (LULC). Due to the high incidence of clouds in the Bahia state, the products from MODIS sensor were used because it presents a high temporal resolution. The purpose of this research was to propose a mapping and monitoring approach to land use and land cover for the state of Bahia using multitemporal data from MODIS sensor, covering the period between 2000 and 2017. The specific objectives were: a) to estimate endmembers (pure pixels) from images of higher spatial resolution (30 m) of OLI / Landsat 8 sensor for later application of the Linear Spectral Mixture Model (LSMM) in products from MODIS sensor (250 m spatial resolution) ; b) to generate a time series of fraction images derived from the MLME between 2000 and 2017 using the estimated endmembers in the previous phase; c) to generate mosaics of the fraction images by calculating the maximum annual value of the proportions for the years 2000 and 2017; d) to generate two LULC thematic maps in the state of Bahia for the years 2000 and 2017 using the mosaics generated in the previous phase, applying the Random Forest classifier; e) to evaluate the accuracy of the LULC maps obtained; and f) qualitatively analyse the time series of the fraction images obtained for the entire analysed period. The results obtained were: 1) the estimated endmembers allowed the improvement of the results regarding error, variability and identification of the components proportions in the images, due to the difficulty in determining the endmembers and that the undue choice of considered pixels as pure in low and moderate spatial resolution products can affect the quality of the fraction images for operational use; 2) the approach using the fraction images containing the maximum annual proportion of the components reduced the data volume, while allowing the separation of LULC classes due to the association between vegetation, soil and shade proportions, extracting the characteristics related to the annual LULC class patterns; 3) The LULC maps for the years 2000 and 2017 obtained a global accuracy of 0.77 and 0.67, respectively, generating the hypothesis that the severe drought that reached the Northeast between 2012 and 2017 influenced the worse performance of the classifier; 4) the use of time series of the fraction images allowed to monitoring the changes occurred in the vegetation and also the

impacts that may be associated to the drought events. Thus, the approach presented here demonstrates the potentiality of the fraction images for the semiautomatic classification and monitoring of vegetation cover at global and regional level.

Keywords: Linear Spectral Mixture Model. Moderate Resolution Imaging Spectroradiometer. Random Forest. Northeast. Bahia state.

LISTA DE FIGURAS

Pág.

Figura 2.1 – Característica sazonal da vegetação e suas variações na reflectância espectral.	13
Figura 2.2 – Exemplificação de diferentes resoluções espaciais e a mistura espectral contida em imagens orbitais.	17
Figura 2.3 – Curvas espectrais de alvos.	18
Figura 2.4 – Processo de reconhecimento de padrões e tendências em grande volume de dados (Knowledge Discovery in Databases – KDD).	19
Figura 2.5 – Fases de treinamento e classificação do <i>Random Forest</i>	21
Figura 3.1 – (a) Localização da área de estudo e tipos de vegetação dos biomas Cerrado (b), Caatinga (c), Mata Atlântica (d) e a precipitação média anual em cada bioma.	22
Figura 3.2 – Classificação climática para o estado da Bahia, de acordo com os critérios Koppen (1936).	27
Figura 3.3 – Qualidade de pixel do sensor MODIS para cada mês abrangendo o estado da Bahia.	29
Figura 4.1 – Representação dos tiles para os produtos MODIS na América do Sul.	32
Figura 4.2 – 37 cenas dos satélites Landsat com Órbita/Ponto que abrangem o estado da Bahia.	33
Figura 4.3 – Mosaico anual utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.	36
Figura 4.4 – Mosaico do período seco utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.	37
Figura 4.5 – Mosaico do período úmido utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.	38
Figura 4.6 – Fluxograma simplificado descrevendo a metodologia proposta. ...	41
Figura 4.7 – Exemplo de seleção dos bits utilizados na imagem QA do produto MOD13Q1.	43
Figura 4.8 – Fluxograma metodológico descrevendo a etapa de estimativa dos <i>endmembers</i>	46
Figura 4.9 – Resposta espectral dos componentes de referência obtidos na imagem em estudo.	47
Figura 4.10 – Representação da composição de um pixel em diferentes resoluções espaciais, exibindo a visão geral em imagem de 30 m (a) e em detalhe um pixel em 250 m (MODIS) (b) e em 30 m (Landsat 8).	49
Figura 4.11 – Representação da proporção de cada amostra calculada por interpretação visual.	51
Figura 5.1 – Equação obtida com a regressão linear múltipla para cada faixa espectral e seus respectivos coeficientes de determinação (r^2).	63
Figura 5.2 – Média e desvio padrão das amostras geradas da fração erro do MLME onde estimado e convencional correspondem à resolução espacial de 250m.	65
Figura 5.3 – RMSE e BIAS das amostras geradas sendo que estimado e convencional correspondem à resolução espacial de 250 m.	66

Figura 5.4 – Detalhe do produto MOD13Q1 utilizando falsa composição colorida em R(MIR) G(NIR) e B(Red) (a) e as respectivas imagens fração.	69
Figura 5.5 – Mosaico das imagens fração contendo o valor máximo das proporções para o ano 2000.	71
Figura 5.6 – Mosaico das imagens fração contendo o valor máximo das proporções para o ano 2017.	72
Figura 5.7 – Gráfico de dispersão dos pontos evidencia a associação entre as classes utilizadas e as proporções do $MLME_{max}$	76
Figura 5.8 – Comportamento temporal do EVI nos biomas Caatinga e Cerrado.	79
Figura 5.9 – Esquema de área considerada ecótono.	82
Figura 5.10 – Mapa base de uso e cobertura da terra para o estado da Bahia referente ao ano 2000.	84
Figura 5.11 – Mapa base de uso e cobertura da terra para o estado da Bahia referente ao ano 2017.	85
Figura 5.11 – Quantificação das classes mapeadas em 2000 e 2017.	87
Figura 5.12 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 para amostras de Caatinga, Cerrado e Mata Atlântica.	92
Figura 5.13 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 observadas separadamente para amostra de Caatinga.	93
Figura 5.14 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 para amostras de conversão de vegetação natural da Caatinga para agricultura perene, degradação da vegetação e assoreamento de corpos hídricos.	94
Figura 5.15 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 observadas separadamente em amostras de degradação da vegetação e assoreamento de corpos hídricos.	95

LISTA DE TABELAS

Pág.

Tabela 2.1 – Exemplos de mapeamentos em escala de bioma ou global para estimativa de mudanças da cobertura da terra que encobrem o estado da Bahia.....	9
Tabela 4.1 – Informações do produto MOD13Q1 do sensor MODIS, satélite Terra.....	32
Tabela 4.2 – Informações sobre o sensor TM a bordo do satélite Landsat 5...	34
Tabela 4.3 – Informações sobre o sensor OLI a bordo do satélite Landsat 8. .	34
Tabela 4.4 – Classes dos mapeamentos para treinamento do classificador e avaliação da acurácia.....	39
Tabela 4.5 – Descrição da imagem <i>VI Quality</i> do produto MOD13Q1.	43
Tabela 4.6 – Polígonos coletados em cada classe de uso e cobertura da terra.....	54
Tabela 4.7 – Classes de uso e cobertura adotadas no estado da Bahia.	55
Tabela 5.1 – Coeficiente de determinação e equação obtida por regressão linear múltipla.	61
Tabela 5.2 – Fator de reflectância dos componentes estimados utilizando a combinação de diferentes sensores e resoluções espaciais.....	64
Tabela 5.3 – Média das amostras geradas da fração erro do MLME onde estimado e convencional correspondem à resolução espacial de 250 m.....	64
Tabela 5.4 – Proporção dos componentes nas resoluções espaciais de 250m e 30m por pixel.....	67
Tabela 5.5 – Matriz de confusão entre aproximadamente 50.000 pixels utilizados para treinamento do classificador RF.	79
Tabela 5.6 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra referente ao ano 2000.....	80
Tabela 5.7 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra referente ao ano 2017.....	81
Tabela 5.8 – Quantificação das classes mapeadas em 2000 e 2017.	86
Tabela 5.9 – Exemplos de áreas de conversão da vegetação nativa da Caatinga em agricultura perene (a) e aumento de solo em corpos hídricos (b).	96

LISTA DE SIGLAS E ABREVIATURAS

AG	Agricultura
BFAST	<i>Breaks For Additive Seasonal and Trend</i>
CA	Caatinga
CE	Cerrado
CH	Corpos Hídricos
EMBRAPA	Empresa Brasileira de Pesquisa e Agropecuária
FPI	Fiscalização Preventiva Integrada na Bahia
IBGE	Instituto Brasileiro de Geografia e Estatística
INEMA	Instituto do Meio Ambiente e Recursos Hídricos - Bahia.
INPE	Instituto Nacional de Pesquisas Espaciais
KDD	<i>Knowledge Discovery in Databases</i>
MAPBIOMAS	Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil
MA	Mata Atlântica
MIR	<i>Short wave Infrared</i> (Infravermelho Médio)
MLME	Modelo Linear de Mistura Espectral
MLME _{ES}	Modelo Linear de Mistura Espectral estimado
MLME _{CO}	Modelo Linear de Mistura Espectral convencional
MMA	Ministério do Meio Ambiente
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NIR	<i>Near Infrared</i> (Infravermelho Próximo)
NPV	<i>Non-photosynthetic Vegetation</i> (Vegetação não fotossinteticamente ativa)
OLI	<i>Operational Land Imager</i>
PMDBBS	Projeto de Monitoramento do Desmatamento dos Biomas Brasileiros por Satélite
PROBIO	Projeto de Conservação e Utilização Sustentável da Diversidade Biológica
PA	Pastagem
PV	<i>Photosynthetic Vegetation</i> (Vegetação fotossinteticamente ativa)
RF	<i>Random Forest</i>
SO	Solo exposto
SWIR	<i>Short-wave Infrared</i> (Infravermelho Médio)
TM	<i>Thematic Mapper</i>
USGS	<i>United State Geological Survey</i>

SUMÁRIO

Pág.

1 INTRODUÇÃO	1
1.1 Objetivos.....	4
1.1.1 Objetivo geral	4
1.1.2 Objetivos específicos	4
2 FUNDAMENTAÇÃO TEÓRICA	5
2.1 Histórico de mapeamento no Nordeste do Brasil.....	5
2.2 Fenologia das espécies	10
2.3 Características espectrais da vegetação	11
2.4 Características temporais da vegetação.....	12
2.5 Ferramentas de monitoramento da dinâmica da vegetação por sensoramento remoto.....	13
2.6 Processamento digital de imagens	15
2.6.1 Modelo linear de mistura espectral	16
2.7 Mineração de dados	19
2.7.1 <i>Random Forest</i>	20
3 ÁREA DE ESTUDO	22
3.1 Vegetação.....	23
3.2 Desmatamento	24
3.3 Caracterização climática.....	26
3.4 Desertificação	29
4 MATERIAIS E MÉTODOS	31
4.1 Sensor MODIS / Terra	31
4.2 Sensores TM e OLI - Landsat.....	33
4.3 Dados auxiliares	38
4.4 Métodos	39
4.5 Processamento de imagens	41
4.5.1 Pré-processamento de imagens MODIS.....	41
4.6 Filtro de nuvem	42
4.7 Seleção de <i>endmembers</i> e aplicação do MLME.....	44
4.8 Aplicação multitemporal do MLME	52
4.9 Classificação por <i>Random Forest</i>	53
4.9.1 Seleção de amostras.....	53
4.9.2 Classificador.....	56
4.9.3 Validação dos resultados	57
4.10 Perfis temporais das imagens fração	59
5 RESULTADOS E DISCUSSÃO	61
5.1 Estimando <i>endmembers</i>	61
5.2 Classificação do uso e cobertura da terra.....	75
5.3 Perfis temporais das imagens fração.....	91
6 CONCLUSÕES E RECOMENDAÇÕES	98
REFERÊNCIAS BIBLIOGRÁFICAS	101

1 INTRODUÇÃO

Os processos de mudança da cobertura vegetal do planeta têm se intensificado nas últimas décadas, especialmente nos trópicos (FEARNSIDE, 1996). A degradação das áreas naturais se inicia, em grande parte, devido ao desmatamento e à substituição da vegetação nativa por pastagens ou culturas de ciclo curto (SAMPAIO, 2005).

Assim, conhecer a extensão e as taxas de degradação da terra para proteger os ecossistemas terrestres de um maior esgotamento tem sido uma das questões mais importantes do nosso tempo (ONU, 2017; REYNOLDS et al., 2007). O Brasil tem um papel protagonista neste contexto, pois abriga não apenas a maior extensão de floresta tropical no mundo, mas também áreas de alto valor de conservação como as savanas e florestas sazonalmente secas (PENNINGTON et al., 2006; CÂMARA et al., 2015).

Neste sentido, o Nordeste brasileiro é a região que apresenta a maior floresta tropical seca da América do Sul (SILVA et al., 2018), possuindo um tipo de vegetação adaptada às condições de semiaridez, conhecida como Caatinga (savana-estépica), e com características de importância global únicas. O bioma ocupa aproximadamente 11% de todo o território nacional, no qual habitam cerca de 27 milhões de habitantes (MMA, 2017), sendo uma das regiões semiáridas mais povoadas do mundo (REDO et al., 2013), o que tem promovido grande pressão no uso da terra sobre a vegetação nativa.

Além disso, essa região tem sido negligenciada e pobremente estudada tanto em termos de programas de conservação quanto de investigação científica, apesar da riqueza biológica e endemismo (PENNINGTON et al., 2006) e muitas áreas susceptíveis à desertificação (SANTOS et al., 2011). Assim, a região Nordeste é considerada ameaçada devido às altas taxas de desmatamento, degradação generalizada, alta fragmentação e o baixo status de proteção da vegetação nativa (MMA, 2017).

Neste cenário, o estado da Bahia, localizado na região Nordeste e ocupando a sexta posição entre os estados brasileiros com maior extensão territorial, tem apresentado grande redução da vegetação nativa durante os últimos anos e

indicação de cont nua degrada o. No estado, predominam-se tr s dos principais biomas brasileiros: Caatinga, Cerrado e Mata Atl ntica. Neste contexto, o estado ocupa a primeira posi o no ranking em  rea desmatada no bioma Mata Atl ntica (FUNDA O SOS MATA ATL NTICA / INPE, 2017), sofreu a maior supress o da vegeta o nativa da Caatinga (2008-2009) dentre todos os estados, permanecendo apenas 53,38% de sua cobertura (MMA / IBAMA, 2011), e, al m disso, do total de 7.247 km² da vegeta o do Cerrado suprimida no Brasil (2010-2011), aproximadamente 1.002 km² foram desmatados apenas na Bahia (MMA, 2015).

Tais mudan as s o induzidas principalmente para a expans o da agricultura, e para o consumo de forma ilegal de lenha nativa pela demanda por carv o nos centros urbanos e industriais (MORAIS et al., 2018; MEDEIROS et al., 2014). Somado a estes fatores, existe a escassez e limita o de pol ticas p blicas para conscientiza o da popula o sobre o manejo adequado das florestas e esfor os para pesquisa e conserva o, especialmente para os biomas Caatinga e Cerrado (FPI, 2014).

As esp cies lenhosas s o especialmente importantes nas regi es semi ridas para a prote o contra desertifica o e resili ncia  s mudan as clim ticas (FAO, 2016), al m de contrib rem para a biodiversidade global e no ciclo global do carbono (ROTENBERG; YAKIR, 2015; POULTER et al., 2014). Em particular, elas exercem papel determinante de muitos processos-chave do ecossistema, como, por exemplo, evapotranspira o e dist rbios de inc ndio, al m dos padr es abi ticos associados (BRESHEARS, 2006). Dessa forma,   medida que a vegeta o   cada vez mais afetada por r pidas mudan as clim ticas e de uso do solo, surge uma grande necessidade de entender os padr es da din mica da cobertura florestal (YANG et al., 2012).

Mudan as na cobertura vegetal, estoques de carbono e produtividade da vegeta o s o informa es que podem contribuir na implementa o de pol ticas p blicas de conserva o das florestas, mantendo a fun o ecol gica do ecossistema no sistema global (ARAG O et al., 2014). Assim, informa es acuradas e atualizadas sobre as mudan as de cobertura da terra s o

essenciais para o planejamento e suporte às tomadas de decisão (USGS, 2011; GÓMEZ et al., 2016), além de subsidiarem recursos para a comunidade científica.

Nas últimas décadas os produtos de Sensoriamento Remoto tornaram-se uma importante fonte de informações para monitorar as mudanças da cobertura da terra. Devido à possibilidade de aquisição de dados sobre grandes extensões geográficas, tais produtos permitiram assim, melhor compreensão dos processos que ocorrem nestas áreas (ANDERSON, 2003).

No entanto, os estudos atuais baseados em dados de observação da Terra são desenvolvidos principalmente a partir de metodologias elaboradas para regiões que apresentam florestas com elevada biomassa e dossel fechado, não sendo adequados para detectar e monitorar a vegetação de clima semiárido, que apresenta variabilidade temporal e espacial (BRANDT et al., 2016; YANG et al., 2012). Em especial, na América do Sul, historicamente a maioria dos esforços para estimar as mudanças da cobertura florestal tem sido focado em florestas tropicais, enquanto poucos estudos têm dedicado atenção para regiões sazonais e com menores taxas de precipitação (BEUCHLE et al., 2015).

Além disso, tendo em vista a necessidade de um estudo em grande escala sobre as tendências e mudanças na cobertura vegetal da região Nordeste, existem limitações de dados orbitais de alta resolução espacial devido à disponibilidade de dados espaço-temporais em uma região altamente dinâmica, reduzindo o seu uso em análises de mudanças à curto prazo. Dessa forma, as abordagens derivadas de séries temporais com sensores de baixa e moderada resolução espacial, mas que apresentam alta resolução temporal, mostram-se como uma alternativa viável para a quantificação destas mudanças (BRANDT et al., 2016).

Uma das abordagens para estimar a cobertura da vegetação que apresenta grande variabilidade temporal e espacial é a utilização do Modelo Linear de Mistura Espectral (MLME). Proposto por Shimabukuro e Smith (1991), o MLME gera imagens fração, a partir da definição de um conjunto de *endmembers*

(*pixels* puros), que reduzem o volume de informações das imagens originais, além de realçar as informações de interesse para análises posteriores.

1.1 Objetivos

1.1.1 Objetivo geral

O objetivo geral deste trabalho é propor uma abordagem de mapeamento e monitoramento do uso e cobertura da terra para o estado da Bahia utilizando dados multitemporais provenientes do sensor MODIS, abrangendo o período entre 2000 e 2017.

1.1.2 Objetivos específicos

Para atingir o objetivo geral desta pesquisa, foram definidos os seguintes objetivos específicos:

- a) estimar os *endmembers* (*pixels* puros) a partir das imagens de melhor resolução espacial do OLI/Landsat 8 para aplicação do Modelo Linear de Mistura Espectral (MLME) nos produtos provenientes do sensor MODIS;
- b) gerar uma série temporal de imagens fração derivadas do MLME nos produtos provenientes do sensor MODIS para o período entre 2000 e 2017, utilizando os *endmembers* estimados na fase anterior;
- c) gerar mosaicos das imagens fração calculando o valor máximo anual das proporções dos componentes para os anos de 2000 e 2017;
- d) gerar dois mapas temáticos de uso e cobertura da terra no estado da Bahia em 2000 e 2017 utilizando os mosaicos gerados na fase anterior, aplicando o classificador *Random Forest*;
- e) avaliar as acurácias dos mapas temáticos de uso e cobertura da terra obtidos;
- f) analisar qualitativamente os perfis temporais das imagens fração obtidas para o período entre 2000 a 2017.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Histórico de mapeamento no Nordeste do Brasil

Considerando a diversificada cobertura vegetal no Nordeste, dentre os seis principais biomas que estão inseridos no território brasileiro, quatro destes são identificados na região: Amazônia, Caatinga, Cerrado e Mata Atlântica. Além disso, existem áreas de transição entre o Cerrado e a Caatinga, formadas por Florestas estacionais decíduas e semidecíduas cujo domínio são característicos da Mata Atlântica (IBGE, 2004). As principais iniciativas de estimativa e monitoramento das mudanças de cobertura da terra em projetos que abrangem o Nordeste se encontram sumarizados neste tópico.

Analisando os mapeamentos em escala nacional dos biomas identificados na região, exceto pelo bioma Amazônia, apenas a Mata Atlântica tem sido alvo de iniciativas de monitoramento. Desde 1990, quando o primeiro “Atlas dos Remanescentes Florestais e Ecossistemas Associados do Bioma Mata Atlântica” foi publicado, o mapeamento e monitoramento deste bioma tornou-se referência para pesquisa científica (FUNDAÇÃO SOS MATA ATLÂNTICA, 2017).

Entretanto, devido à dificuldade de obtenção de imagens orbitais sem cobertura de nuvens para os estados do Nordeste, somente no período entre 1995-2000 foram acrescentadas áreas parciais da Bahia neste Atlas, utilizando os sensores *Thematic Mapper* (TM/Landsat 5) e *Enhanced Thematic Mapper Plus* (ETM+/Landsat 7), cuja resolução espacial e temporal são de 30 metros e 16 dias, respectivamente. Nos mapeamentos a partir de 2014, os dados foram produzidos em escala de 1:50.000, utilizando imagens orbitais do sensor *Operational Land Imager* (OLI/Landsat-8) (FUNDAÇÃO SOS MATA ATLÂNTICA, 2017) para mapeamento dos alvos por interpretação visual.

Em contrapartida, para os biomas Cerrado e Caatinga o mapeamento e o entendimento acerca das mudanças da cobertura vegetal ainda permanece limitado, tendo poucas iniciativas públicas para o mapeamento a nível dos biomas e esforços para pesquisa e conservação (BEUCHLE et al., 2015).

Inicialmente, o programa PROBIO (Projeto de Conservação e Utilização Sustentável da Diversidade Biológica) implementado por meio do decreto 1.354 de 29 de dezembro de 1994, teve por objetivo realizar o levantamento dos remanescentes da cobertura vegetal dos biomas brasileiros, na escala de 1:250.000, utilizando dados orbitais provenientes do sensor TM/Landsat-5 referentes ao ano de 2002 (MMA, 2014).

Como atualização do PROBIO, subseqüentemente foi criado o PMDBBS (Projeto de Monitoramento do Desmatamento dos Biomas Brasileiros por Satélite) pela Secretaria de Biodiversidade e Florestas do Ministério do Meio Ambiente (SBF/MMA), que incluíram o mapeamento da Caatinga e Cerrado para os anos de 2008 e 2009, e posteriormente entre 2009 e 2011 apenas para o Cerrado (MMA, 2015; MMA, 2011). Todos os dados são provenientes dos sensores Landsat e incluem também dados do CBERS (*China–Brazil Earth Resources Satellite*) para o bioma Caatinga, também para o mapeamento por interpretação visual dos alvos em escala 1:50.000.

Além desses, o Laboratório de Processamento de Imagens e Geoprocessamento (LAPIG) da Universidade Federal de Goiás (UFG) iniciou em 2008 a geração de alertas de desmatamentos para o bioma Cerrado assim como a análise de padrões e tendências espaciais e temporais. Atualmente o LAPIG disponibiliza dados de pontos coletados em campo entre 2010 e 2017 para todos os biomas, entretanto para o estado da Bahia não existem dados para os biomas Caatinga e Mata Atlântica (LAPIG, 2018).

Juntamente com a união de instituições brasileiras, a primeira versão do projeto intitulado TerraClass (Mapeamento do Uso e Cobertura Vegetal do Cerrado) foi lançado em 2013. Para este projeto, foram utilizadas como base de mapeamento 118 cenas do sensor Operational Land Imager (OLI/ Landsat 8), referentes ao ano de 2013. O mapeamento abrange todo o bioma também por interpretação visual, fornecendo dados compatíveis com a escala cartográfica de 1:250.000 (BRASIL, 2015).

Em 2015 foi iniciado o MAPBIOMAS (Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil) que utiliza processamento em nuvem a

partir da plataforma *Google Earth Engine* para gerar uma série histórica de mapas anuais de uso e cobertura da terra entre 2000 e 2017 para todos os biomas brasileiros.

O MAPBIOMAS se tornou o único projeto de mapeamento frequente e atualizado para todo o território brasileiro utilizando resolução espacial de 30 metros (SOUZA JR; AZEVEDO, 2017). Entretanto, embora o MAPBIOMAS represente um grande avanço na avaliação das mudanças na cobertura da terra, especificamente para a Caatinga os resultados da classificação ainda são impactados pela fenologia da vegetação e pela qualidade das imagens de satélite disponíveis (FRANCA ROCHA; CHAVES, 2017), apresentando a acurácia total de 66,8% no bioma quando comparado aos demais, tornando-se o resultado mais inferior do projeto.

Na Bahia, como exemplo de mapeamento da vegetação em nível estadual, o INEMA (Instituto do Meio Ambiente e Recursos Hídricos) disponibiliza o mapa da vegetação do estado referente ao ano de 1998, utilizando imagens impressas do sensor TM/Landsat 5, numa escala de 1:250.000 (INEMA, 2014). Espera-se, em 2019, que seja divulgado pelo INEMA o atual mapeamento da cobertura vegetal do estado em escala de 1:50.000 utilizando imagens RapidEye referentes ao ano de 2015. Tais informações serão de grande relevância para o controle da supressão vegetal, fiscalização e monitoramento, além do planejamento da conservação da vegetação no estado da Bahia (SEMA, 2017).

Além dessas iniciativas, outros estudos em escala global (GlobeLand30 - CHEN et al., 2015; Hansen et al., 2013, BELLOT et al., 2014; BRANNSTROM et al., 2008;) e por bioma (BEUCHLE et al., 2015; SILVA; SANO, 2016; BORGES; SANO, 2014; CASTELLETI et al., 2003) foram gerados para este fim (Tabela 2.1).

Dessa forma, observa-se que existe um número, mesmo que limitado, de mapeamentos que fornecem informações sobre a vegetação do Nordeste no que se refere ao uso e cobertura da terra. Entretanto, esses conjuntos de

dados fornecem informações apenas em um único período no tempo ou por bioma, não compreendendo o mapeamento para toda a região.

Além disso, todos estes mapeamentos adotaram diferentes legendas e utilizaram dados orbitais dos satélites Landsat, que pode ser limitado pela menor frequência de revisita (LI et al., 2017; HILKER et al., 2009; WULDER et al., 2008), e ainda mais afetado pela incidência de nuvens (ZHU; WOODCOCK, 2014; ASNER, 2001). Também foram observados que estudos de caso não são abundantes, assim como há carência de validação dos resultados e publicações em periódicos revisados por pares. Portanto, é necessário rever estudos anteriores sobre a cobertura vegetal do Nordeste, especialmente o bioma Caatinga.

Tabela 2.1 – Exemplos de mapeamentos em escala de bioma ou global para estimativa de mudanças da cobertura da terra que encobrem o estado da Bahia.

Autor	Escala / Status	Objetivo / Escala Temporal	Sensor / Resolução	Legenda
GFC¹ (Hansen et al., 2013)	Global / Todos os Biomas Brasileiros	Cobertura Florestal ano 2000 Perda e Ganho da Cobertura entre 2001-2015	Landsat (30 m)	% de Cobertura Florestal e Ganhos e Perdas.
MapBiomas²	Todos os Biomas Brasileiros	Uso e Cobertura da Terra/Anual 2000-2017	Landsat	Floresta Densa, Aberta, Pasto, Agricultura, Campos Naturais, Urbano, Água, entre outros.
PROBIO³	Todos os Biomas Brasileiros (diferentes metodologias)	Uso e Cobertura da Terra (2002)	Landsat	Classificação do IBGE.
PMDBBS⁴	Continuação do PROBIO	Desmatamento 2002-2008, 2008-2009	Landsat	Atualização dos dados do PROBIO com novos polígonos de desmatamento.
Beuchle et al. (2015)	Biomas Cerrado e Caatinga (Baseado em Amostras)	Cobertura da Terra 1990-2000-2010	Landsat	Cobertura Florestal. Mosaico e Outras Tipos de Cobertura, Água.
Borges; Sano (2014)	Bioma Cerrado	Mapeamento do uso e cobertura na Bahia (2012)	MODIS (250 m)	Vegetação Campestre, Floresta Estacional, Culturas agrícolas, Vegetação secundária.
Silva; Sano (2016)	Bioma Cerrado	Mapeamento do uso e cobertura (2012)	Rapideye (5 m)	Vegetação Campestre, Savânica e Florestal, Culturas agrícolas e pastagens.
SOS Mata Atlântica	Bioma Mata Atlântica	Mapeamento, desmatamento, regeneração (1990-2017)	Landsat	Vegetação Nativa

¹ GFC: Produto Global de Mudanças da Cobertura Florestal

² MapBiomas: Projeto de Mapeamento Brasileiro do Uso e Cobertura da Terra Anual

³ PROBIO: Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira

⁴ PMDBBS: Projeto de Monitoramento do Desmatamento dos Biomas Brasileiros por Satélite

Fonte: Produção do autor.

2.2 Fenologia das espécies

As características fisiográficas, os fatores abióticos e as atividades humanas estão relacionadas diretamente com a distribuição da vegetação e a sua fenologia (CHUINE et al., 2000). Uma melhor compreensão sobre as mudanças fenológicas das espécies em resposta às variáveis do ambiente como, por exemplo, mudanças na precipitação e temperatura, pode fornecer evidências de como as espécies estão sendo influenciadas por mudanças globais (LEE et al., 2002). Entretanto, a magnitude e a direção dos impactos causados por esses eventos nos ecossistemas ainda permanecem incertas (WANG et al., 2016).

A fim de prever o funcionamento e a resposta a longo prazo da dinâmica e estabilidade de um ecossistema, estudos fenológicos tanto a nível de organismos quanto em modelos de escalas regionais e globais têm sido realizados (CHUINE et al., 2000). Assim, o conhecimento sobre a distribuição, tipos e variações fenológicas da cobertura vegetal é indispensável para o planejamento eficiente de políticas públicas (CANAVESI et al., 2005).

Em regiões onde os períodos secos e úmidos são distintos e bem definidos, os eventos fenológicos das plantas são diretamente afetados pela periodicidade das chuvas e conseqüentemente pela disponibilidade de água no solo (SINGH; KUSHWAHA, 2005; JOLLY; RUNNING, 2004; PAVÓN; BRIONES, 2001). Assim, os padrões fenológicos das espécies que ocorrem em florestas secas são mais pronunciados quando comparados com florestas menos sazonais (JUSTINIANO; FREDERICKSEN, 2000).

De acordo com Reich e Borchert (1984), em geral a intensidade da seca sazonal, o potencial de aproveitamento hídrico e controle da perda de água relacionam-se com a abscisão foliar – queda foliar – em espécies florestais. O crescimento da maioria das espécies do Cerrado e Caatinga está relacionado com a sazonalidade, sendo frequente a renovação foliar e floração no período da seca (OLIVEIRA, 2008; FIGUEIREDO, 2008). Entretanto, o padrão fenológico pode variar ao longo do tempo e espaço. Como por exemplo, determinadas espécies lenhosas da Caatinga perdem suas folhas no início da

estação seca, enquanto outras espécies permanecem com suas folhas ao longo de todo o período de estiagem (MACHADO et al., 1997; BORCHERT et al., 2002).

Em relação às espécies de Mata Atlântica, Borchert (1999) observou que à medida em que as espécies lenhosas crescem em ambientes com maior suprimento de água no solo, as mudanças foliares são mais independentes da sazonalidade climática, visto que a disponibilidade de água protegeria as plantas do estresse hídrico sazonal. Pereira et al. (2008) apontam que nas espécies arbóreas de Floresta Atlântica estudadas, a abscisão foliar esteve principalmente relacionada aos períodos de menores índices pluviométricos e entre a transição para a estação úmida. Dessa forma, em espécies de Mata Atlântica, a queda foliar também pode ocorrer para minimizar ou evitar o estresse hídrico (SANTOS, 2011).

A Bahia apresenta 54% da sua área inserida no bioma Caatinga, cuja vegetação é adaptada às condições de clima semiárido (LEAL et al., 2003). Dessa forma, quando se trata de estudos relacionados a vegetação deste bioma, é importante considerar algumas particularidades da resposta espectral da vegetação dada a elevada variabilidade sazonal, pois a grande variação da biomassa foliar ao longo do tempo é um dos problemas relacionados aos estudos nestas áreas (MALDONADO, 1999).

2.3 Características espectrais da vegetação

Referente ao comportamento espectral da vegetação, as alterações fenológicas e morfológicas impactam diretamente na resposta espectral do alvo. Estes impactos podem variar de acordo com a fisionomia vegetal e também, a faixa espectral e o ângulo de visada do sensor utilizado (NOVO, 2010).

Se tratando de propriedades de reflectância, as diferenças na porcentagem de fechamento do dossel, umidade do solo e biomassa podem fazer com que uma determinada fisionomia vegetal apresente diferenças significativas em relação à outra devido às influências de fundo (*background*), permitindo, assim, a

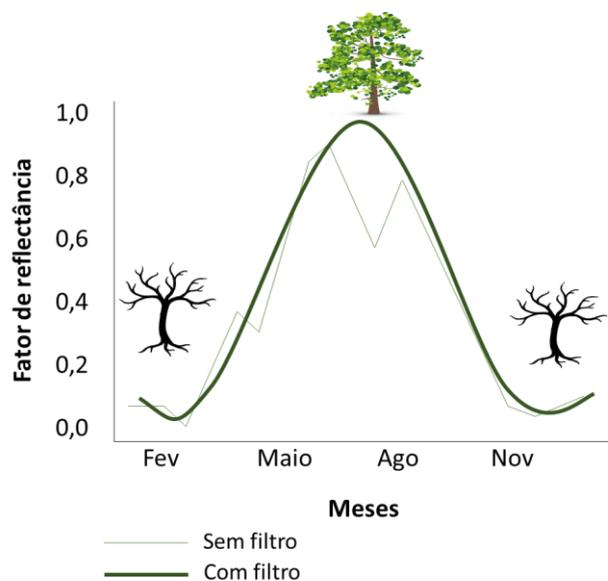
discriminação entre os alvos. Portanto, para diferenciar a vegetação utilizando dados de sensores remotos, é essencial o conhecimento sobre o ciclo fenológico da vegetação em estudo (JENSEN, 2009).

Segundo Maldonado (1999), devido à baixa atividade fotossintética observada em estratos de aspecto seco que compõem a vegetação, existe um importante componente na resposta espectral em função do sombreamento da porção lenhosa (troncos e galhos). Dessa forma, observa-se a importância do sombreamento sobre o solo ocasionado pela densidade de galhos, uma vez que a ausência do material foliar verde diminui a influência da componente folha na resposta espectral. Assim, quanto menor a cobertura vegetal, maior será a influência do solo na resposta espectral, devendo-se considerar uma seleção apropriada de faixas espectrais sensíveis à cobertura dos solos.

2.4 Características temporais da vegetação

O desenvolvimento de dosséis florestais segue ciclos relativamente previsíveis a cada ano, exceto quando estejam sob estresse, forte ocorrência não sazonal e mudanças abióticas que podem alterar o ciclo fenológico (Figura 2.1). Dessa forma, é necessário estar atento às épocas mais propícias para a identificação de diferentes tipos de vegetação ou extração de informações biofísicas, assim como observar os períodos de precipitação mais intensos e de maior incidência de nuvens. Estes motivos levam a necessidade da utilização de dados provenientes de sensores com alta resolução temporal (JENSEN, 2009).

Figura 2.1 – Característica sazonal da vegetação e suas variações na reflectância espectral.



Fonte: Produção do autor.

Afim de prever a cobertura lenhosa em uma região da África, Brandt et al. (2016) pressupõem que durante o período de seca as árvores e arbustos têm fotossíntese ativa, enquanto ocorre a redução de plantas herbáceas no final da estação chuvosa. Do mesmo modo, no Brasil estudos demonstram que a época seca é mais apropriada para discriminar os tipos de vegetação natural existentes no semiárido, uma vez que durante a época úmida ocorre a homogeneização da vegetação dificultando a diferenciação entre classes (FRANCISCO et al., 2012; MALDONADO, 1999).

2.5 Ferramentas de monitoramento da dinâmica da vegetação por sensoriamento remoto

A coleção de imagens orbitais de uma mesma região do planeta e em diferentes períodos de aquisição é denominado de série temporal de imagens de Sensoriamento Remoto. Séries temporais podem ser utilizadas para compreender a dinâmica temporal (BROCKWELL; DAVIS, 2002), sazonal e

espacial, assim como os fatores que controlam tais dinâmicas e variações, sejam relacionadas à fenômenos naturais ou com eventos de causa antrópica.

Devido à capacidade consistente e a frequência temporal regular, as ferramentas de Sensoriamento Remoto apresentam potencial significativo para monitorar as dinâmicas da vegetação em escala global e regional (VERBESSELT et al., 2012). De acordo com Verbesselt et al. (2010), as mudanças nos ecossistemas terrestres podem ser divididas em três classes: (1) mudanças relacionadas à sazonalidade ou fenologia das espécies, que são afetadas por flutuações climáticas como temperatura e precipitação; (2) mudanças abruptas causadas por distúrbios tais como inundações, fogo, desmatamento e outros fatores de causa antropogênica; e (3) mudanças graduais que seguem uma tendência linear devido à mudanças na tendência de precipitação e degradação da terra a longo prazo.

Diversas técnicas são utilizadas para extrair informações de séries temporais, incluindo técnicas de detecção de mudanças que minimizam a variação sazonal, separando os efeitos de tendência das mudanças ocorridas em períodos específicos, como também na filtragem de ruídos nos sinais dos dados observados (VERBESSELT et al., 2012; BROCKWELL, 2002).

Devido à necessidade do monitoramento da vegetação através do tempo quando se pretende analisar a dinâmica do ecossistema e quais sucessões de mudanças estão acontecendo, Jensen (2009) afirma que dados de alta resolução temporal obtidos por satélites são de grande importância para estudos sucessionais. Dessa forma, dados provenientes do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) são amplamente utilizados para este fim devido à sua revisita diária, permitindo a comparação temporal e espacial das condições da vegetação (PETUS et al., 2013). Entretanto, pequenas alterações ambientais podem não ser detectadas devido à resolução espacial de 250 metros (WALKER et al., 2012).

Desta maneira, dados orbitais dos satélites Landsat têm sido amplamente utilizados em Sensoriamento Remoto devido a resolução espacial média de 30 metros dos sensores, embora, a incidência de nuvens é um dos principais

problemas encontrados (ZHU; WOODCOK, 2014) o que pode influenciar as análises de séries temporais no monitoramento da dinâmica da vegetação (JENSEN, 2009) em escala regional.

Adicionalmente, muitos estudos de monitoramento da vegetação em regiões áridas e semiáridas têm utilizado índices de vegetação como o NDVI (Índice de Vegetação da Diferença Normalizada) para estimar a dinâmica da vegetação e a diferenciação entre classes, como empregado por Paudel e Andersen (2010). Como também têm sido utilizadas análises com modelos de mistura espectral (MME) para melhor explicar a heterogeneidade da vegetação e solo em paisagens áridas (THORP et al., 2013; YANG et al., 2012).

Comparando a performance de ambas as metodologias utilizando o NDVI e MME (SONNENSCHNEIN et al., 2011; YANG et al., 2012) ressalta-se o uso do MME como o método de escolha para quantificar a cobertura vegetal em análises temporais de regiões áridas e semiáridas, especialmente devido à técnica demonstrar precisão em estimar a cobertura lenhosa. Além disso, o NDVI pode superestimar a dinâmica da vegetação e apresentar susceptibilidade aos efeitos de background e sombra (HUETE; JACKSON, 1988), podendo não ser a melhor opção para estudos de fenologia e de mudanças da cobertura vegetal.

Por outro lado, mudanças da resposta da vegetação ocorrem em múltiplas escalas de tempo e se torna complexo distinguir tais mudanças em séries temporais. Além disso, as características das resoluções temporais, espaciais e espectrais de dados orbitais influenciarão na detecção de mudanças abruptas, que ocorrem a curto prazo (VERBESSELT et al., 2012). Assim, alguns métodos de detecção de mudanças que consideram as variações em escala sazonal para detectar mudanças em tendências a longo prazo, desconsiderando as flutuações sazonais (WATTS; LAFFAN, 2014) são comumente utilizados.

2.6 Processamento digital de imagens

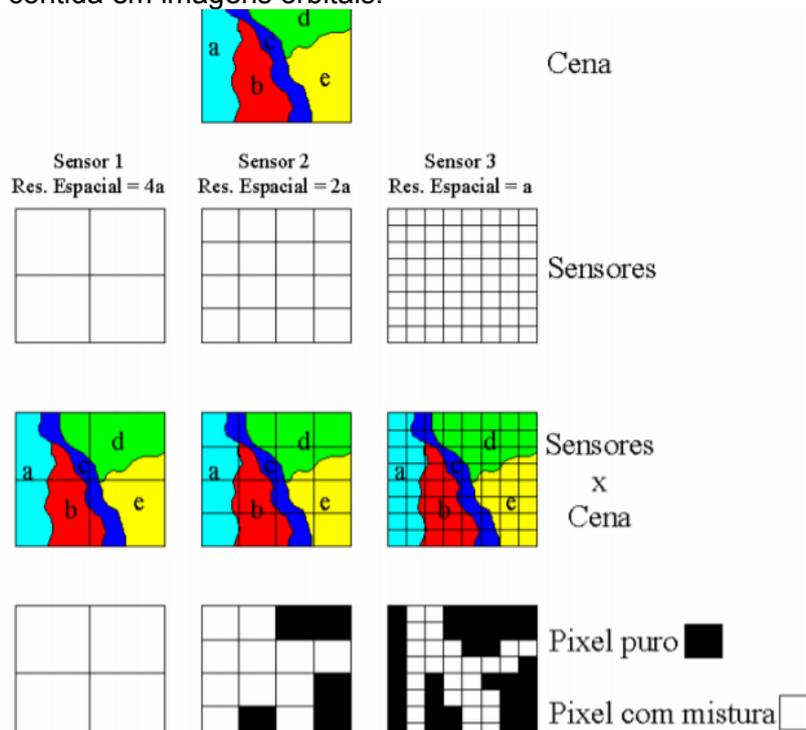
Esta seção apresenta breve descrição das técnicas de processamento digital de imagens a serem utilizadas para o desenvolvimento deste trabalho.

2.6.1 Modelo linear de mistura espectral

A radiância registrada pelo sensor é uma soma integrada das radiâncias de todos os objetos ou materiais contidos dentro do campo de visada instantâneo (instantaneous field of view – IFOV), como, por exemplo, sombra, solo e a copa das árvores. Deste modo, cada pixel fornece o resultado das interações da radiação eletromagnética com múltiplos componentes, não representando a composição físico-química de um único objeto exclusivamente (SHIMABUKURO et al., 2014). Assim, a complexidade da composição de um pixel tem sido comumente referida pelo termo mistura espectral (SHIMABUKURO; PONZONI, 2017; SHIMABUKURO; SMITH, 1995) (Figura 2.2).

Diversos modelos matemáticos já foram propostos para a identificação da proporção de mistura no pixel (KESHAVA; MUSTARD, 2002; GARCÍA-HARO et al., 2005; de ALCÂNTARA et al., 2008), sendo o Modelo Linear de Mistura Espectral (MLME) proposto por Shimabukuro e Smith (1991) uma das técnicas mais comumente utilizadas. Uma grande quantidade de trabalhos apresenta a utilização do MLME ao redor do mundo e atualmente é considerado uma ferramenta importante para operacionalizar projetos de larga escala (SHIMABUKURO; PONZONI, 2017).

Figura 2.2 – Exemplificação de diferentes resoluções espaciais e a mistura espectral contida em imagens orbitais.



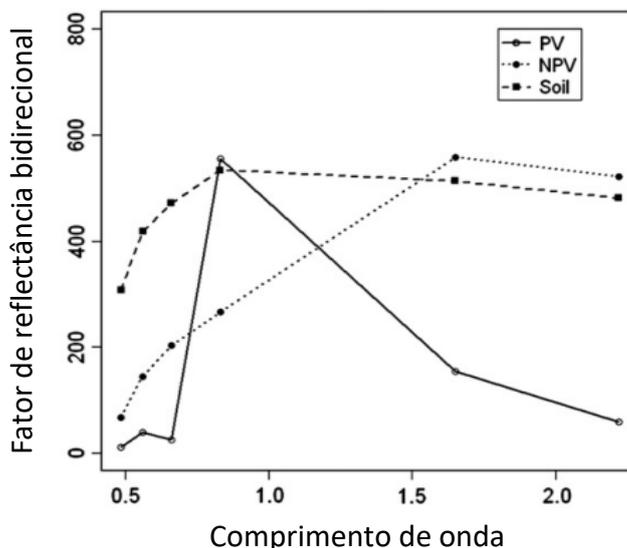
Fonte: Piromal (2006).

Como resultado do MLME, imagens fração são geradas contendo informações sobre a proporção dos componentes contidos em cada *pixel*. Tais informações geradas são amplamente utilizadas no estudo das mudanças sazonais da cobertura da terra e distúrbios da vegetação (ADAMI et al., 2018), mapeamento da exploração seletiva (ASNER et al., 2005; ANWAR; STEIN, 2012), áreas queimadas (QUINTANO et al., 2006; ANDERSON et al., 2005; SHIMABUKURO et al., 2009; SHIMABUKURO et al., 2017), degradação florestal (SOUZA et al., 2003; SOUZA et al., 2005), mudanças associadas ao desmatamento e degradação florestal (SHIMABUKURO et al., 2019; SOUZA et al., 2013) e outras abordagens (PITHON et al., 2013).

A aplicação do MLME é possível com o conhecimento *a priori* da resposta espectral dos componentes de referência, como, por exemplo, a partir da sua curva espectral (Figura 2.3). Uma das abordagens mais comumente empregadas para a aplicação do MLME é a aquisição de *pixels* puros

(*endmembers*) a partir da reflectância espectral dos componentes disponíveis na própria imagem de estudo (SHIMABUKURO; PONZONI, 2017).

Figura 2.3 – Curvas espectrais de alvos.



Exemplo do comportamento espectral de três *endmembers* selecionados. Onde: PV fração fotossinteticamente ativa, NPV: fração não-fotossinteticamente ativa e Soil: Solo.

Fonte: Adaptado de YANG et al. (2012).

Em imagens de alta ou média resolução espacial, assume-se que há maior probabilidade de encontrar *pixels* puros, ou seja, *pixels* que incluem um único componente de referência, disponíveis na imagem. Entretanto, em sensores de baixa e moderada resolução espacial, a natureza mista dos *pixels* limita essa abordagem devido à dificuldade ou mesmo à impossibilidade de obtenção de *pixels* puros (DE FREITAS et al., 2008). Principalmente em estudos de escala global ou regional, a determinação desses *endmembers* permanece um desafio (MEYER; OKIN, 2015).

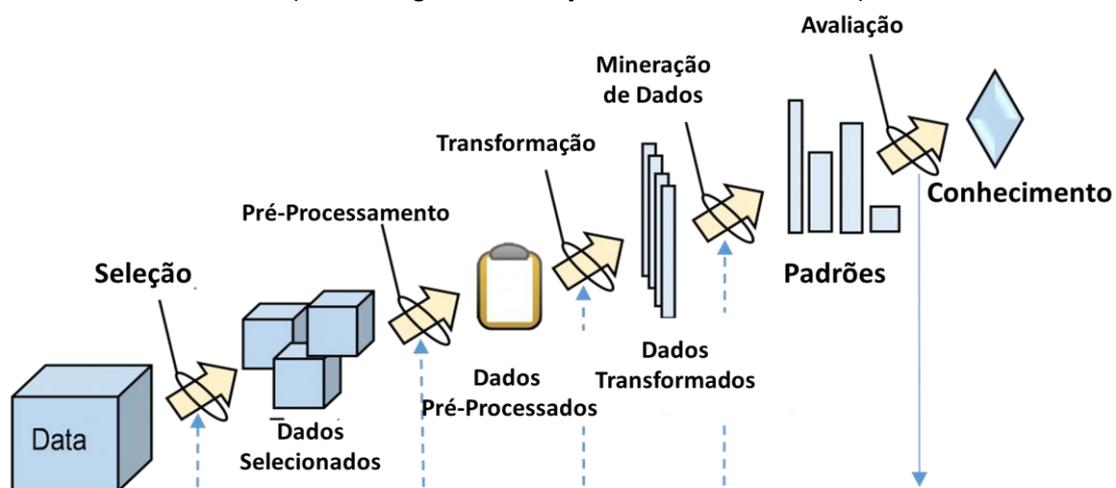
Nas últimas décadas uma grande quantidade de dados com diferentes resoluções espectral, temporal e espacial vem sendo disponibilizada à comunidade de usuários de Sensoriamento Remoto. Assim, com a crescente quantidade de produtos disponibilizados, estudos anteriores têm demonstrado

a capacidade de fundir observações de diferentes resoluções e sensores como uma maneira promissora de aumentar a potencialidade nos estudos de observação da Terra (LI et al., 2017; DE FREITAS et al., 2008).

2.7 Mineração de dados

Com o crescente aumento da quantidade de dados nas últimas décadas, a extração de informações de forma manual tornou-se inviável. Dessa forma, devido à necessidade de obter informação útil a partir de um grande volume de dados, diversas técnicas computacionais foram desenvolvidas afim de automatizar o processo de reconhecimento de padrões e tendências, surgindo o campo da descoberta de conhecimento em banco de dados (*Knowledge Discovery in Databases*) (FAYYAD et al., 1996) (Figura 2.4).

Figura 2.4 – Processo de reconhecimento de padrões e tendências em grande volume de dados (Knowledge Discovery in Databases – KDD).



Fonte: Adaptado de Fayyad et al. (1996).

Diante deste contexto, a mineração de dados é um conjunto de métodos que consiste na aplicação de algoritmos, de reconhecimento de padrões e de aprendizado de máquina para extrair padrões, correlações e tendências dos dados (FAYYAD et al., 1996). No campo do Sensoriamento Remoto, a

mineração de dados tem sido amplamente utilizada e a extração de informações espaciais e espectrais de séries temporais para a classificação de imagens (KÖRTING, 2012) por *pixel* ou por objeto, consiste em uma das etapas deste processo.

Para gerar a classificação de imagens a partir do reconhecimento de padrões, métodos supervisionados são utilizados a partir do pré-estabelecimento de classes. Assim, por meio da coleta de amostras, os algoritmos são treinados para entender os padrões das classes (LAROSE, 2014).

Dentre os classificadores supervisionados de mineração de dados, existem as árvores de decisão que dividem hierarquicamente um conjunto de dados com base em uma geração de regras. A partir disso, subconjuntos mais homogêneos serão divididos até que as condições predefinidas das classes sejam atendidas (BREIMAN et al., 1984). Uma das vantagens para esse tipo de classificador, está na possibilidade de representação de dados de treinamento dentro do espaço multitemporal. Assim, classificações de uso e cobertura da terra baseadas em árvores de decisão têm sido realizadas em estudos de larga escala. (HANSEN et al., 2008, 2014).

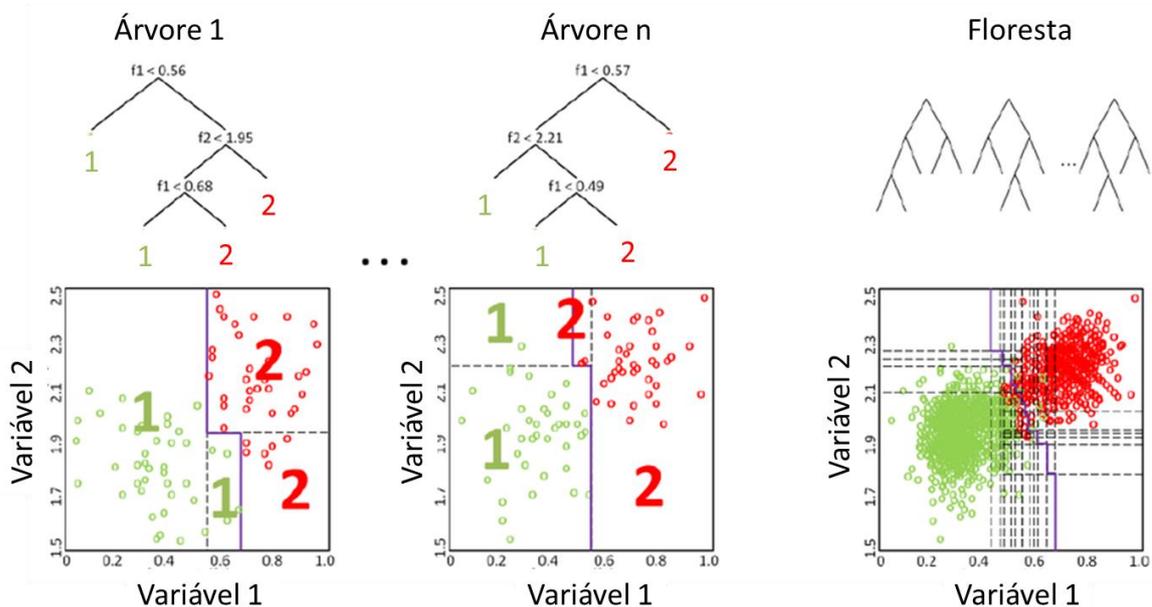
2.7.1 Random Forest

Random Forest é definido por Breiman (2001) como um classificador composto por uma coleção de Árvores de Decisão. Por ser um classificador que tem apresentado elevadas acurácias nos resultados, rápida velocidade de processamento e menos sensível à ruídos (BREIMAN, 2001; RODRIGUEZ-GALIANO et al., 2012; DU et al., 2015), nas últimas décadas o RF tem sido utilizado com grande frequência.

Baseado em um subconjunto de amostras de treinamento, cada árvore de decisão é gerada, independente, a partir de um subconjunto de atributos selecionado aleatoriamente. A cada nó da árvore, um número aleatório de atributos é selecionado, até que haja um ganho de informações para dividir o nó (Figura 2.5).

O crescimento da árvore ocorre a partir do nó raiz, que contém a variável de maior contribuição para discriminar as classes de amostra. A partir disso, as partições resultam em ramificações e nós descendentes até que uma resposta seja atingida, cujo ponto é o nó de decisão (folha) da árvore (SHANG et al., 2007; BASHIR et al., 2014). Todo esse processo de construção de uma única árvore é repetido até que uma quantidade predefinida de árvores seja concluída no modelo (BREIMAN, 2001; BELGIU; DRAGUT, 2016).

Figura 2.5 – Fases de treinamento e classificação do *Random Forest*.



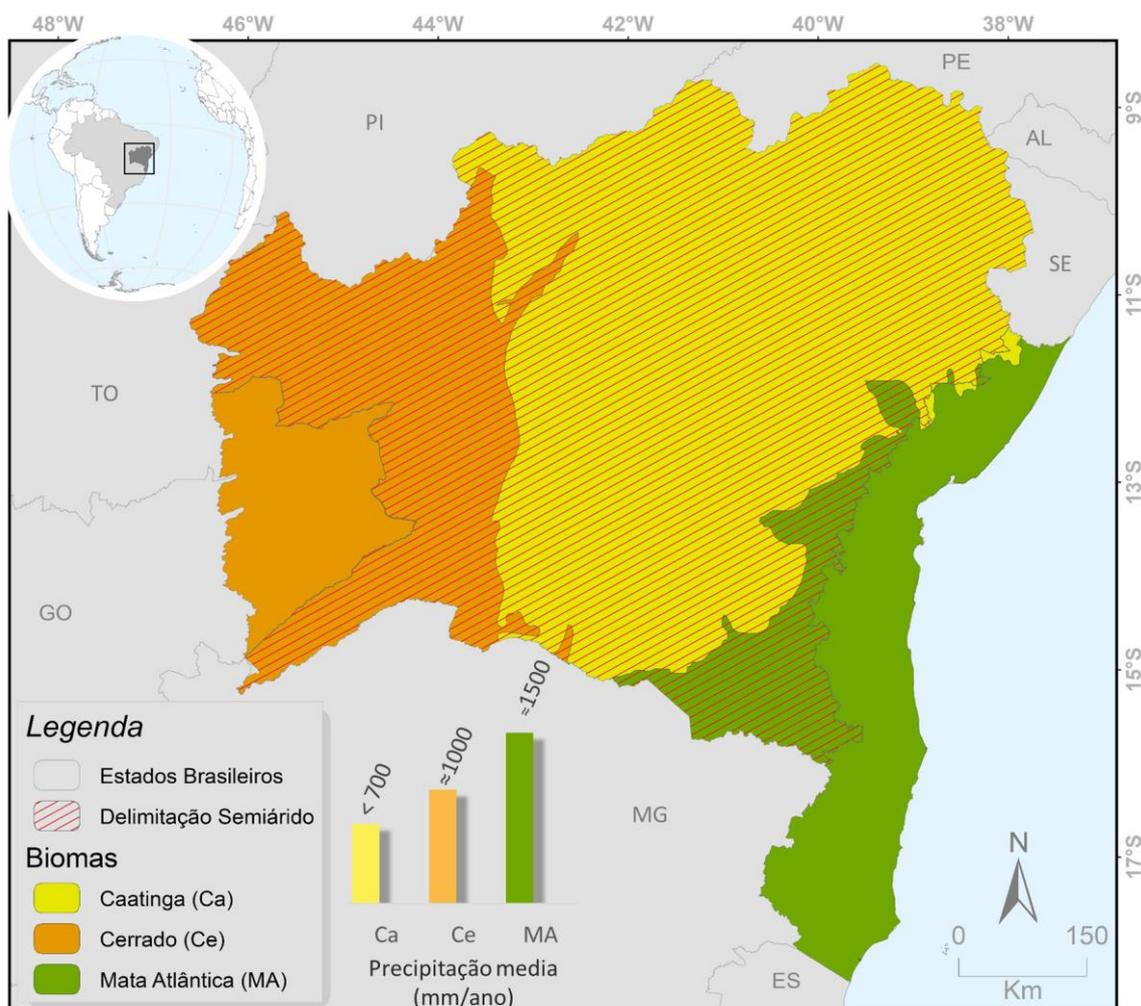
Fonte: Adaptado de Hanselmann (2009).

O classificador RF pode lidar com conjuntos de um grande número de atributos. O uso dos dados de entrada baseados em amostragem torna o algoritmo mais poderoso do que uma simples árvore, apresentando elevada taxa de acerto quando testado em diferentes conjuntos de dados (BELLE, 2008). A combinação de diversas árvores de decisão tende a uma melhor taxa de acerto, visto que o erro em uma única classificação é sobreposto pela combinação de múltiplas classificações (SESNIE et al., 2010; COSTA, 2014, GIROLAMO NETO, 2018).

3 ÁREA DE ESTUDO

A área de estudo compreende o estado da Bahia, localizado na região Nordeste do Brasil, entre as coordenadas geográficas 08°29'14" e 18°24'34" de latitude sul e 37°18'11" e 46°59'58" de longitude oeste, possuindo extensão territorial de 565.453 km² (Figura 3.1). O estado apresenta os biomas Caatinga, Cerrado e Mata Atlântica, cobrindo 53%, 27% e 19% de todo o estado, respectivamente.

Figura 3.1 – (a) Localização da área de estudo e tipos de vegetação dos biomas Cerrado (b), Caatinga (c), Mata Atlântica (d) e a precipitação média anual em cada bioma.



Fonte: Produção do autor.

3.1 Vegetação

O estado da Bahia detém um imenso potencial ambiental representado pelos biomas existentes, além dos ecossistemas de restingas, lagunas e manguezais. O Cerrado destaca-se por sua rica biodiversidade e seu potencial aquífero, com destaque para a Bacia do Rio São Francisco. Nestes espaços concentram-se atualmente as mais importantes atividades agrícolas do estado (DOURADO, 2017).

A Caatinga predomina na maior porção do território, apresentando diversidade de paisagens e riqueza biológica ímpar. Enquanto a Mata Atlântica abriga remanescentes da segunda maior floresta tropical úmida do Brasil, que originalmente estendia-se do Rio Grande do Norte ao Rio Grande do Sul, partindo do litoral e adentrando o território (DOURADO, 2017).

Referente ao setor agrícola, no Brasil foram criadas novas regras sustentáveis para o cultivo e a comercialização da soja, sendo firmado em 2006 o acordo conhecido como a Moratória da soja e que teve por objetivo inibir a comercialização ou financiamento desta cultura oriunda de áreas desmatadas no bioma Amazônia após julho de 2008 (HIRAKURI et al., 2014; NEPSTAD et al., 2014; ABIOVE, 2017). Neste cenário, a expansão de áreas para a produção de soja foi prevista, principalmente, sobre áreas de pastagens degradadas do bioma Cerrado (HIRAKURI et al., 2014; ALMAGRO et al., 2017).

Além disso, nos últimos anos a região entre os estados do Maranhão, Tocantins, Piauí e Bahia (acrônimo MATOPIBA) se tornou o maior exemplo referente ao movimento de migração das fronteiras agrícolas (SANTOS, 2007; ESQUERDO et al., 2015), e, por isto continua atraindo a atenção da mídia nacional (NOLTE et al., 2017), como ocorre na região oeste do estado da Bahia.

Neste cenário, municípios como Barreiras e Luís Eduardo Magalhães destacam-se pela intensa transformação impulsionada pela produção agrícola, considerados como regiões bem-sucedidas no cenário agrícola nacional. Entretanto, a escassez de políticas contra o desmatamento no Cerrado tem

favorecido altas taxas de conversão das áreas nativas em lavouras (PIRES et al., 2016).

3.2 Desmatamento

Como já apresentado, o estado da Bahia possui significativa importância ecológica em virtude da sua extensão e biodiversidade. Entretanto, não existe um modelo efetivo de uso sustentável da vegetação e diversas atividades, com ênfase para a agricultura e agronegócio, têm ocasionado o indiscriminado desmatamento da cobertura vegetal e consequente destruição e desequilíbrio ambiental (FPI, 2014).

Gradativamente novas áreas são abertas, de forma lenta ou acelerada, ocasionando o desaparecimento das diversas formas de vegetação natural, e dando lugar, por exemplo, a empreendimentos agropecuários, atividades de mineração, estradas e infraestrutura. Além disso, cresce também a demanda por produtos da flora para suprimento energético no processo industrial, como também por subprodutos da madeira (FPI, 2014).

Portanto, apesar da importância da Caatinga, Cerrado e Mata Atlântica para a manutenção da biodiversidade e do equilíbrio ecológico, os mesmos têm sofrido intensa supressão de sua vegetação. Na Bahia, essa problemática se deve principalmente ao consumo de lenha nativa, explorada de forma ilegal e para fins domésticos e industriais na produção de carvão, utilizado como matriz energética, além da especulação imobiliária, da pecuária extensiva e da agricultura irrigada em massa (SILVA et al., 2013). Salienta-se que, na região do Cerrado e Caatinga, a condição de clima quente e seco favorece ainda a propagação do fogo que, quando descontrolado, se transforma em incêndio florestal (FPI, 2014). Este fato torna ambos os biomas entre os mais afetados pela recorrência de incêndios florestais no Brasil (ARAGÃO et al., 2019).

Em termos históricos, o bioma Cerrado teve a sua área suprimida em 43,6% (2002) e em 48,89% (2011) por toda a sua abrangência no Brasil. Entre 2010-2011 foram suprimidos cerca de 7.247 km² da sua cobertura vegetal, sendo 1.003 km² apenas no estado da Bahia. Neste mesmo período, destaca-se que

dentre os dez municípios brasileiros que apresentaram as maiores taxas de supressão, quatro deles são baianos, sendo: Formosa do Rio Preto, São Desidério, Correntina e Jaborandi, o que coloca a Bahia na segunda posição no ranking de maior número de municípios da lista (MMA, 2015).

No que se refere ao bioma Caatinga, destaca-se, como dado preocupante, a área dos remanescentes desta vegetação. Em números absolutos, a Caatinga teve sua cobertura vegetal original em 2008 reduzida de 443.039 km² para 441.117 km² em 2009 no Brasil. Analisando os resultados divulgados pelo MMA e IBAMA (2011), foi identificado, em termos de área, que a Bahia também foi o estado que mais sofreu supressão da Caatinga entre 2008-2009. Da sua área original, restam apenas 300.927 km² no estado e que cerca de 638 km² se encontra como área antropizada. Entre os quarenta primeiros municípios elencados no ranking de maior taxa de desmatamento, quinze deles também pertencem ao estado da Bahia (MMA/IBAMA, 2011).

Em relação ao bioma Mata Atlântica, o total de área desmatada foi de aproximadamente 290.750 km² em todo o território nacional (2015-2016), com aumento de 57,7% na taxa de desmatamento em relação ao período anterior (2014-2015). No ranking dentre os 17 estados mapeados neste período, a Bahia ocupa a primeira posição em maior área desmatada, obtendo 122.880 km² em relação aos 39.970 km² (2014-2015) (Fundação SOS Mata Atlântica/INPE, 2017).

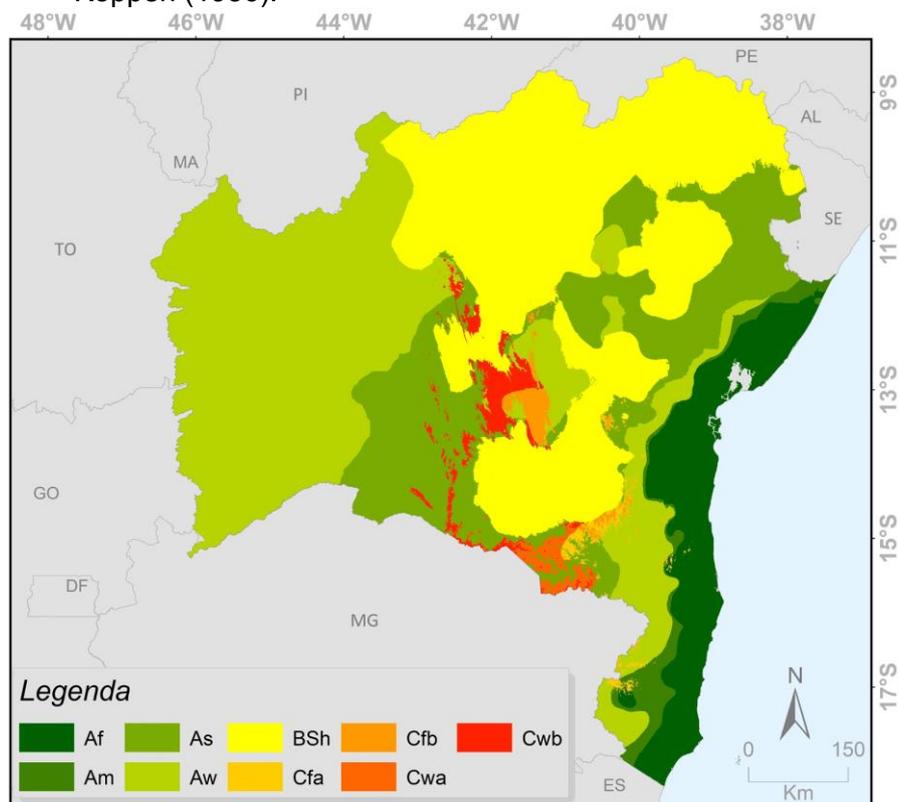
O histórico do desmatamento na Bahia apresentados neste tópico para os três biomas presentes no estado indica uma significativa supressão da vegetação nativa e um forte indício de que as políticas governamentais adotadas para a redução do desmatamento estão favorecendo o avanço e a pressão sobre tais áreas. Tais políticas, no entanto, precisam ser repensadas e direcionadas para potencializar a mitigação de consequências danosas e o desencadeamento de grandes impactos, muitas vezes irreversíveis.

3.3 Caracterização climática

A tipologia climática do estado é caracterizada por uma diversidade de domínios, com alta variabilidade pluviométrica devido aos diferentes sistemas meteorológicos atuantes nesta região, como a Zona de Convergência Intertropical (ZCIT), Vórtices Ciclônicos (VCAN), Zona de Convergência do Atlântico Sul (ZCAS), brisas e ventos, além de um relevo constituído por planícies, vales, serras e montanhas (MOLION; BERNARDO, 2002).

De acordo com a classificação de Köppen (1936), dos doze tipos climáticos encontrados no território brasileiro, a Bahia é o estado que apresenta a maior variabilidade de tipologias. Ressalta-se que, das seis classes climáticas observadas no estado, grande parte está inserida em clima semiárido seco e tropical com inverno seco (Figura 3.2).

Figura 3.2 – Classificação climática para o estado da Bahia, de acordo com os critérios Koppen (1936).



Onde: Af – Clima tropical sem estação seca, Am – Clima Tropical com alternância entre estações, As – Tropical com verão seco, Aw - Tropical com inverno seco, Bsh – Clima semiárido seco; Cfa – Clima Oceânico subtropical úmido sem estação seca e com verão quente; Cfb - Clima Oceânico subtropical úmido sem estação seca com verão temperado, Cwa - Clima subtropical úmido com inverno seco e verão quente e Cwb - Clima subtropical úmido com verão seco temperado.

Fonte: Adaptado de Alvares et al. (2013).

Os períodos chuvosos podem variar de acordo com a região, sendo observados que totais médios de precipitação variam de 300 mm a 2.000 mm por ano, ou até mesmo ultrapassando valores de 2.000 em determinadas áreas (KOUSKY, 1979) e temperaturas médias anuais variando de 18°C a 36°C (ALVARES et al., 2013).

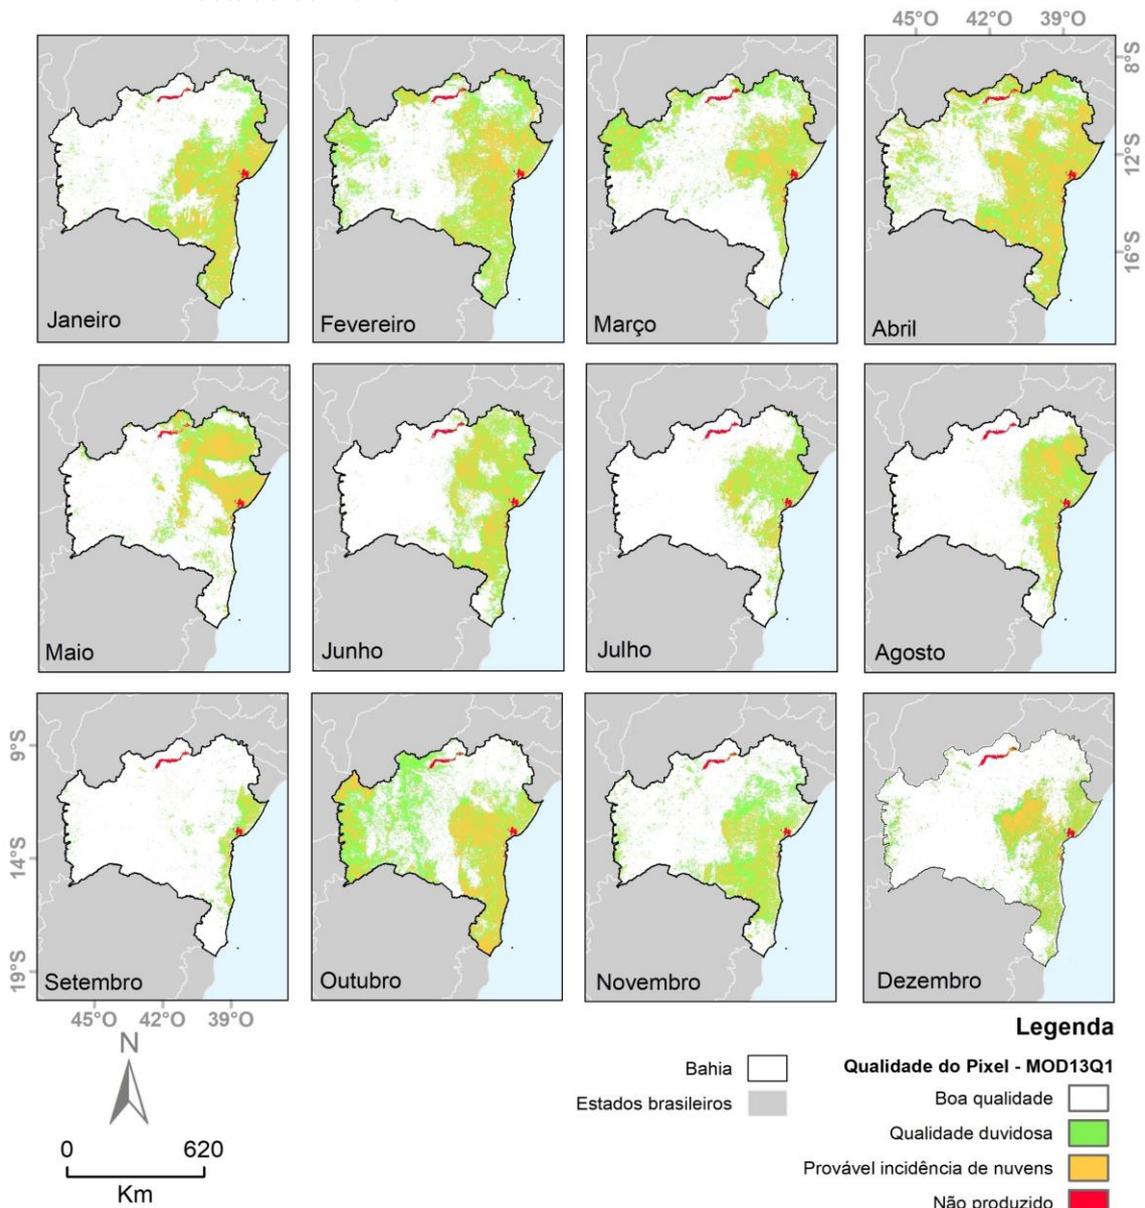
De acordo com Palharini e Vila (2017), ao analisarem a classificação de nuvens no Nordeste do Brasil, foi observado um forte sinal de nuvens sobre as áreas

costeiras. Isso pode ser explicado pelo fato de que os ventos são geralmente perpendiculares à costa e transportam muita umidade do oceano para o continente, contribuindo para a formação de nuvens rasas.

Do mesmo modo, Sano et al. (2007) verificaram a influência da cobertura de nuvens em um conjunto de dados Landsat TM e ETM + no Cerrado brasileiro e, como resultado, foi verificado a menor influência da cobertura de nuvens quando comparado à Amazônia brasileira. Entretanto, a aquisição de dados do tipo Landsat livre de nuvens (no mínimo 10% de cobertura de nuvens) é severamente afetada durante a estação chuvosa, o que pode restringir estudos relacionados às mudanças sazonais na vegetação natural do Cerrado ou no monitoramento da cobertura da terra utilizando uma base mensal.

Observando as imagens de qualidade (*Quality Assurance*) dos produtos MODIS (MOD13Q1), que fornecem dados diários de cobertura da Terra, nota-se, no estado da Bahia, a grande variabilidade espacial e temporal de *pixels* que apresentam qualidade duvidosa e/ou provável incidência de nuvens (Figura 3.3). Especialmente no leste do estado, inserido o bioma Mata Atlântica, não é observado um único mês que apresente *pixels* com boa qualidade para toda a região. Apenas no mês de setembro é observado o aumento na disponibilidade de dados com melhor qualidade em grande parte do estado. Porém, fica evidente a restrição na utilização dos produtos de Sensoriamento Remoto com baixa resolução temporal.

Figura 3.3 – Qualidade de pixel do sensor MODIS para cada mês abrangendo o estado da Bahia.



Fonte: Produção do autor.

3.4 Desertificação

O conceito de desertificação pela UNCCD (Convenção das Nações Unidas para o Combate à Desertificação) foi estabelecido como a “degradação da terra em regiões áridas, semiáridas e subúmidas secas, como resultado de diversos

fatores, incluindo a variação climática e as atividades humanas” (ORGANIZAÇÃO DAS NAÇÕES UNIDAS, 1997; BRASIL, 2004).

No contexto climático, o aumento da temperatura e evapotranspiração, redução da precipitação e a escassez pluviométrica acarreta vários desequilíbrios hidrológicos, degradação dos solos e deficiência do crescimento vegetativo. Além disso, solos suscetíveis à erosão e embasamento contendo rochas que dificultam o acúmulo de água subterrânea são fatores que contribuem para o avanço da desertificação (DOURADO, 2017).

Tomasella et al. (2018), classificaram áreas prioritárias no Nordeste brasileiro em diferentes estágios de degradação do solo, sendo que, na Bahia, os municípios de Guanambi, Irecê, Juazeiro e Jeremoabo apresentaram altas taxas de degradação. Os autores evidenciaram que a degradação do solo está altamente relacionada ao manejo intenso utilizado, explorando os recursos além da capacidade de resiliência do ecossistema, como também há evidências que comprovam os efeitos negativos da seca severa que afeta o Nordeste desde 2012.

4 MATERIAIS E MÉTODOS

4.1 Sensor MODIS / Terra

Uma alternativa para a limitação de dados para o monitoramento da cobertura vegetal por meio de séries temporais na Bahia, é a obtenção de dados do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) que se encontra a bordo das plataformas Terra e Aqua. Este sensor adquire imagens da superfície da Terra a cada 1 ou 2 dias (JUSTICE et al., 2002; SOARES et al., 2007), permitindo uma melhor análise da dinâmica do uso e da cobertura vegetal da área de estudo (ANDERSON et al., 2005; WARDLOW et al., 2007; ANJOS et al., 2013) quando comparado à sensores que apresentam restrição na frequência de produtos disponibilizados. O sensor MODIS disponibiliza vários produtos denominados *ready-to-use* (prontos para uso), tais como reflectância de superfície, temperatura de superfície, produtividade primária líquida e índices de vegetação (BORGES; SANO, 2014).

Para a realização desta dissertação foi utilizado o produto MOD13Q1 que disponibiliza as imagens índices de vegetação (NDVI e EVI), incluindo às bandas espectrais utilizadas para a geração destes índices: azul, vermelho, infravermelho próximo e uma banda localizada na faixa do infravermelho médio (Tabela 4.1). Este produto apresenta estas imagens geradas automaticamente e disponibilizadas na forma de mosaicos quinzenais, mensais e anuais.

As resoluções espaciais disponíveis para este produto são de 250 m, 500 m e 1 km, sendo selecionadas temporalmente para fornecer dados livres de nuvens, através da seleção de *pixels* com o máximo valor de NDVI. Estes dados apresentam-se também atmosféricamente corrigidos e o produto é gerado considerando o ajuste ao nadir para evitar distorções devido à compressão de dados nos *pixels* localizados nas bordas das imagens (DIDAN et al., 2015).

Tabela 4.1 – Informações do produto MOD13Q1 do sensor MODIS, satélite Terra.

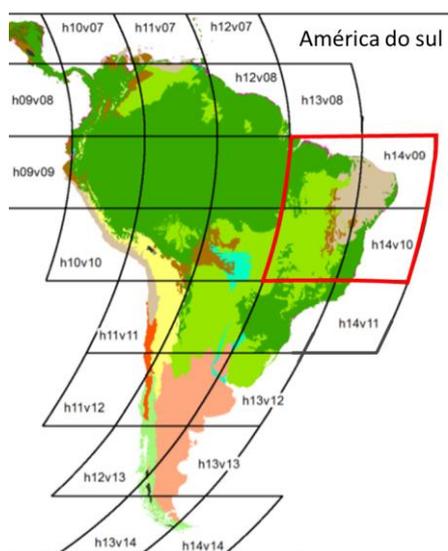
Sensor MODIS – TERRA	Comprimento de Onda (µm)
Banda 1 – <i>Red</i>	0,620 – 0,670
Banda 2 – <i>NIR</i> ¹	0,841 – 0,876
Banda 3 – <i>Blue</i>	0,459 – 0,479
Banda 7 – <i>MIR</i> ²	2,105 – 2,155

¹NIR = Infravermelho próximo; ²MIR = Infravermelho médio.

Fonte: Adaptado de USGS (2000).

Dessa forma, foram adquiridas todas as composições de 16 dias na resolução espacial de 250 m, para o período de 2000 a 2017, referentes aos *tiles* (grade) H13V10, H13V09, H14V10, H14V09 que recobrem todo o estado da Bahia (Figura 4.1). Todos os dados foram obtidos no website do EarthData – NASA (<https://ladsweb.modaps.eosdis.nasa.gov>). Assim, foram obtidas 8.220 imagens para todo o período de estudo, representando aproximadamente 76 GB de arquivos.

Figura 4.1 – Representação dos tiles para os produtos MODIS na América do Sul.



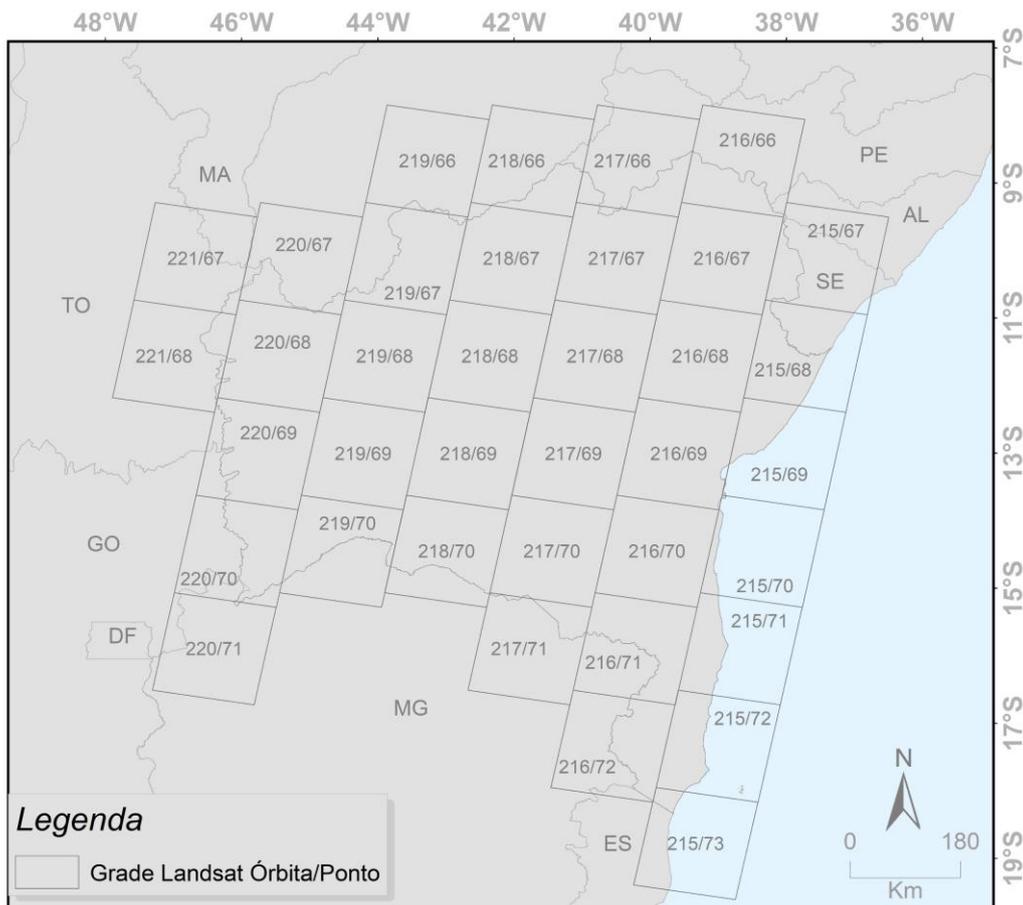
Onde: Os *tiles* representados em vermelho abrangem o estado da Bahia.

Fonte: Adaptado de Clark; Aide (2011).

4.2 Sensores TM e OLI - Landsat

Considerando a melhor resolução espacial dos sensores a bordo dos satélites Landsat quando comparada às imagens orbitais obtidas do sensor MODIS, neste trabalho foram, então, adquiridas imagens orbitais dos sensores TM (*Thematic Mapper*) e OLI (*Operational Land Imager*) (United States Geological Survey - USGS) convertidas para reflectância de superfície, disponibilizadas para download no website (<http://earthexplorer.usgs.gov/>) de modo a compatibilizar com os dados MODIS de 2000 e 2017. Para isto, foram utilizadas as bandas espectrais 2 a 7 (Tabelas 4.2 e 4.3) em cada imagem obtida dos sensores (Figura 4.2).

Figura 4.2 – 37 cenas dos satélites Landsat com Órbita/Ponto que abrangem o estado da Bahia.



Fonte: Produção do autor.

Tabela 4.2 – Informações sobre o sensor TM a bordo do satélite Landsat 5.

Sensor TM Landsat 5 (Bandas)	Comprimento de Onda (μm)	Resolução espacial (m)
Banda 1 - <i>Blue</i>	0,45-0,52	30
Banda 2 - <i>Green</i>	0,52-0,60	30
Banda 3 - <i>Red</i>	0,63-0,69	30
Banda 4 – <i>NIR</i> ¹	0,76-0,90	30
Banda 5 – <i>SWIR</i> ² 1	1,55-1,75	30
Banda 7 – <i>SWIR</i> ² 2	2,08-2,35	30

¹ NIR = Infravermelho próximo; ² SWIR = Infravermelho de ondas curtas.

Fonte: Adaptado de USGS (2019).

Tabela 4.3 – Informações sobre o sensor OLI a bordo do satélite Landsat 8.

Sensor OLI Landsat 8 (Bandas)	Comprimento de Onda (μm)	Resolução espacial (m)
Banda 1 – <i>Coastal aerosol</i>	0,43 – 0,45	30
Banda 2 – <i>Blue</i>	0,45 – 0,51	30
Banda 3 – <i>Green</i>	0,53 – 0,59	30
Banda 4 – <i>Red</i>	0,64 – 0,67	30
Banda 5 – <i>NIR</i> ¹	0,85 – 0,88	30
Banda 6 – <i>SWIR</i> ² 1	1,57 – 1,65	30
Banda 7 – <i>SWIR</i> ² 2	2,11 – 2,29	30
Banda 8 - <i>Panchromatic</i>	0,50 – 0,68	15
Banda 9 - <i>Cirrus</i>	1,36-1,38	30

¹ NIR = Infravermelho próximo; ² SWIR = Infravermelho de ondas curtas.

Fonte: Adaptado de USGS (2019).

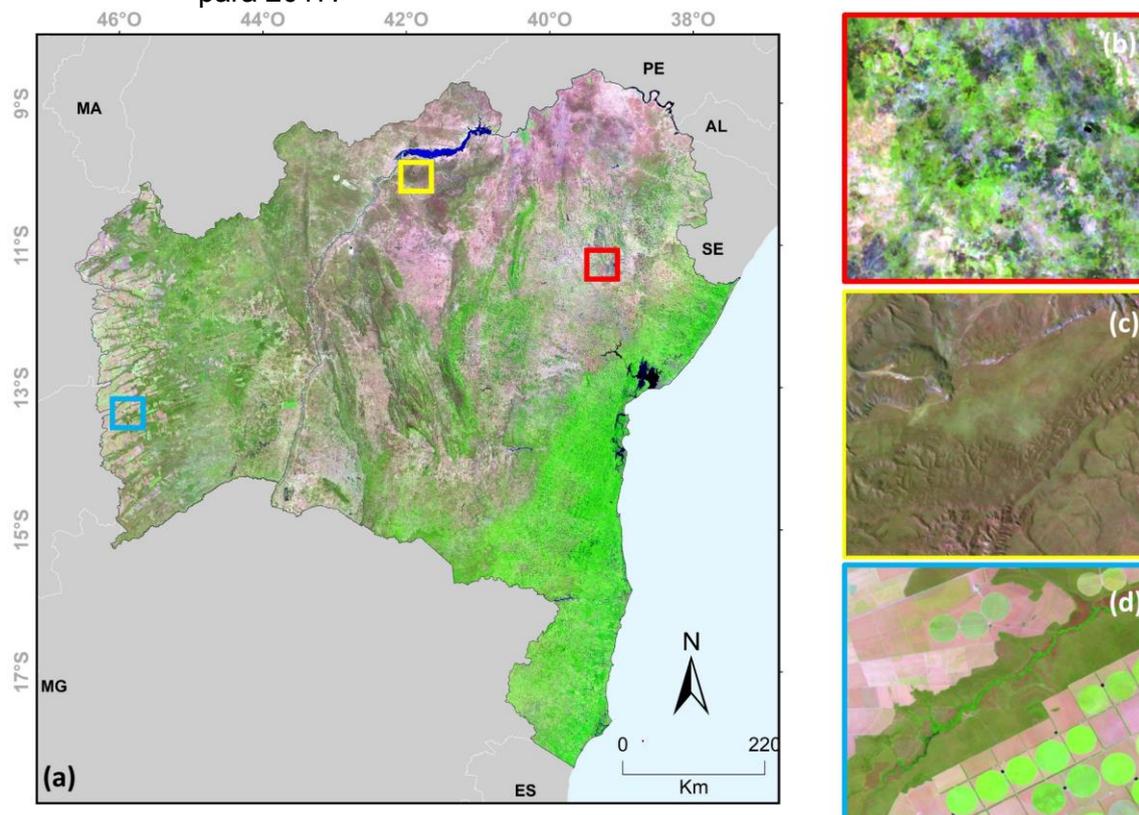
Os satélites Landsat 5 e 8 possuem resolução temporal de 16 dias, e, desta forma, apresentam maior probabilidade de apresentarem cenas com grande interferência de nuvens. Este fato restringe o uso de dados destes satélites no estado da Bahia pois dificulta a construção de séries temporais livre de nuvens.

Dessa forma, com os dados provenientes dos sensores Landsat, foram gerados mosaicos compreendendo todo o ano de 2000 e 2017 (Figura 4.3), um único período seco (agosto a dezembro) (Figura 4.4) e um único período úmido (janeiro a março) (Figura 4.5) apresentando a menor incidência de nuvens e maior variação na sazonalidade da vegetação.

Para este fim, a seleção e composição dos mosaicos foram gerados na plataforma *Google Earth Engine*, por permitir a rápida exploração e visualização de dados orbitais globais provenientes de satélites. Os mosaicos foram, então, gerados a partir da seleção de todas as imagens existentes na plataforma para cada ano pré-estabelecido, que compreendeu cerca de 848 cenas por ano para o estado, e, em seguida, realizado a filtragem de nuvens utilizando algoritmos de detecção e remoção de nuvens já implementados na própria plataforma. Por fim, uma redução das cenas consideradas no intervalo temporal para cada ano foi aplicada utilizando o valor da mediada dos *pixels* para gerar os mosaicos finais.

Assim, todos os mosaicos gerados foram utilizados como dados auxiliares na coleta de amostras dos processos realizados nesta dissertação. Entretanto, ressalta-se que, devido à resolução temporal dos sensores Landsat e à dificuldade na filtragem de nuvens, mesmo após os processamentos para a geração dos mosaicos muitas áreas apresentaram *pixels* sem valor e/ou ainda incidência de nuvens.

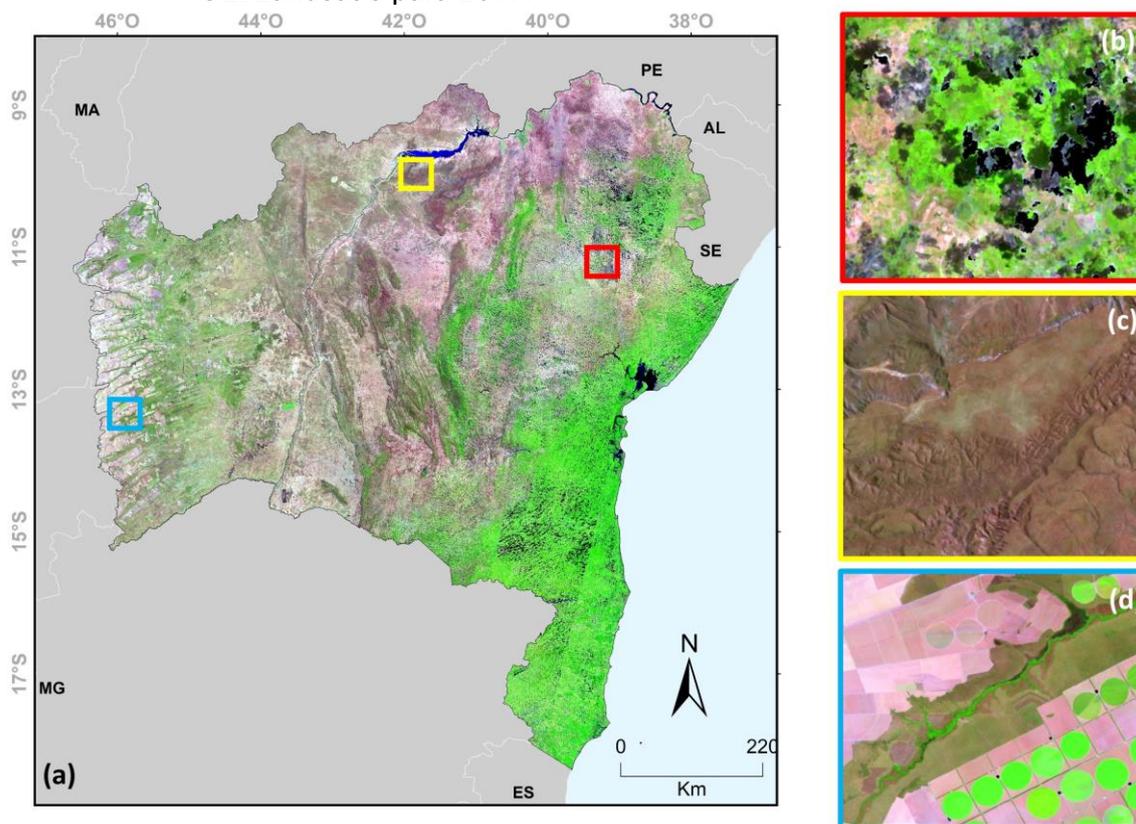
Figura 4.3 – Mosaico anual utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.



Onde: (a) mosaico anual utilizando dados provenientes do sensor OLI/Landsat 8 com menor incidência de nuvens em composição R(6)G(5)B(4), (b) detalhe de áreas com nuvens (latitude $-10^{\circ}59'36''$ e longitude $-39^{\circ}03'57''$), (c) vegetação florestada da Caatinga (latitude $-09^{\circ}58'15''$ e longitude $-41^{\circ}49'10''$) e (d) áreas agrícolas (latitude $-13^{\circ}11'25''$ e longitude $-45^{\circ}57'48''$).

Fonte: Produção do autor.

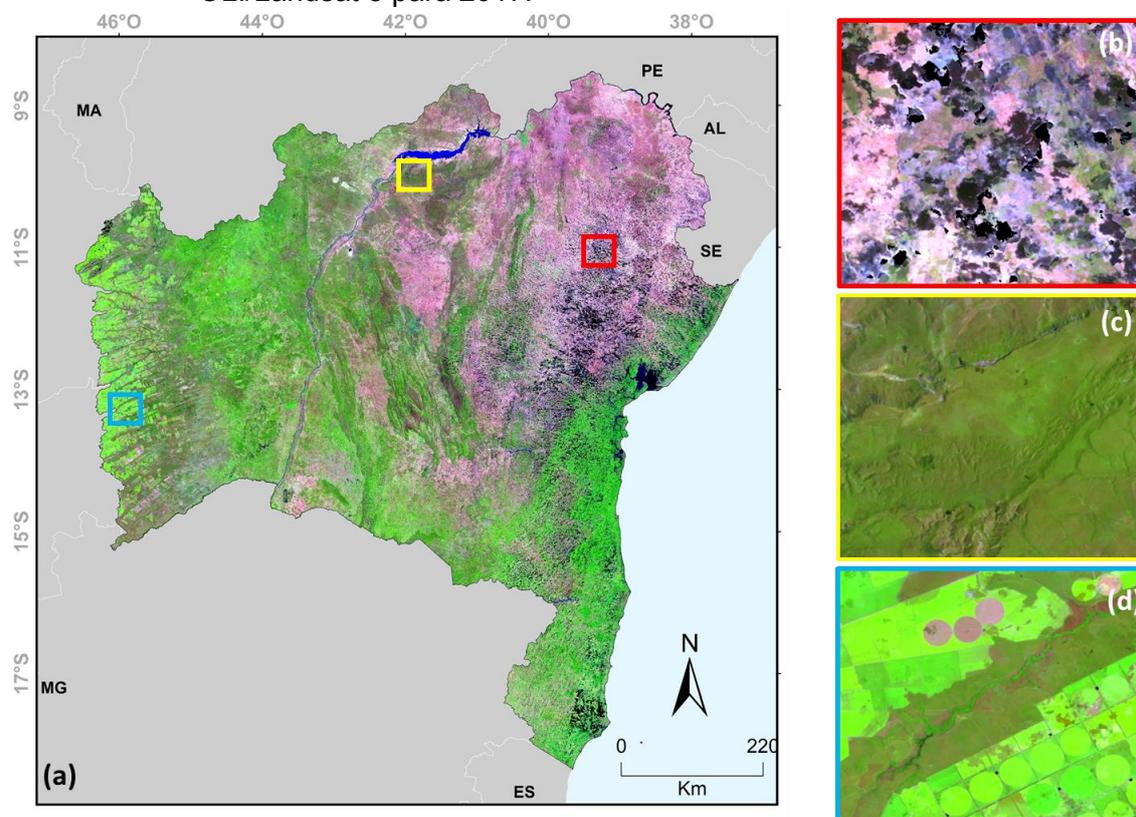
Figura 4.4 – Mosaico do período seco utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.



Onde: (a) mosaico do período seco (estabelecido para esta dissertação entre os meses de agosto a dezembro) utilizando dados provenientes do sensor OLI/Landsat 8 com menor incidência de nuvens em composição R(6)G(5)B(4), (b) detalhe de áreas com nuvens (latitude $-10^{\circ}59'36''$ e longitude $-39^{\circ}03'57''$), (c) vegetação florestada da Caatinga (latitude $-09^{\circ}58'15''$ e longitude $-41^{\circ}49'10''$) e (d) áreas agrícolas (latitude $-13^{\circ}11'25''$ e longitude $-45^{\circ}57'48''$).

Fonte: Produção do autor.

Figura 4.5 – Mosaico do período úmido utilizando dados provenientes do sensor OLI/Landsat 8 para 2017.



Onde: (a) mosaico do período úmido (estabelecido para esta dissertação entre os meses de janeiro a março) utilizando dados provenientes do sensor OLI/Landsat 8 com menor incidência de nuvens em composição R(6)G(5)B(4), (b) detalhe de áreas com nuvens (latitude $-10^{\circ}59'36''$ e longitude $-39^{\circ}03'57''$), (c) vegetação florestada da Caatinga (latitude $-09^{\circ}58'15''$ e longitude $-41^{\circ}49'10''$) e (d) áreas agrícolas (latitude $-13^{\circ}11'25''$ e longitude $-45^{\circ}57'48''$).

Fonte: Produção do autor.

4.3 Dados auxiliares

Para auxiliar na coleta de amostras de treinamento para os passos de classificação, foram obtidos dados oficiais de mapeamento realizados para os três biomas (Tabela 4.4). Tendo em vista a dificuldade na coleta de amostras representativas, em especial em zonas de transição entre Caatinga, Cerrado e

Mata Atlântica, estes dados foram utilizados como referência, sendo: Mapeamento de vegetação remanescente da Caatinga referente ao período 2009-2010 e Mapeamento de vegetação remanescente do Cerrado referente ao período 2010-2011, ambos realizado pelo PMDBBS, bem como o Atlas de Remanescentes Florestais da Mata Atlântica de 2016. Devido à variação na escala temporal dos mapeamentos, uma filtragem foi realizada excluindo polígonos cujas classes foram alteradas ao longo do período analisado, de modo a obter assim, feições existentes das três classes para os anos 2000 e 2017.

Tabela 4.4 – Classes dos mapeamentos para treinamento do classificador e avaliação da acurácia.

Bioma/Projeto	Classe	Período/Ano de mapeamento
Caatinga (PMDDBSS)	Vegetação remanescente	2009-2010
Cerrado (PMDDBSS)	Vegetação remanescente	2010-2011
Mata Atlântica (Fundação SOS Mata Atlântica / INPE)	Vegetação remanescente	2016

Fonte: Produção do autor.

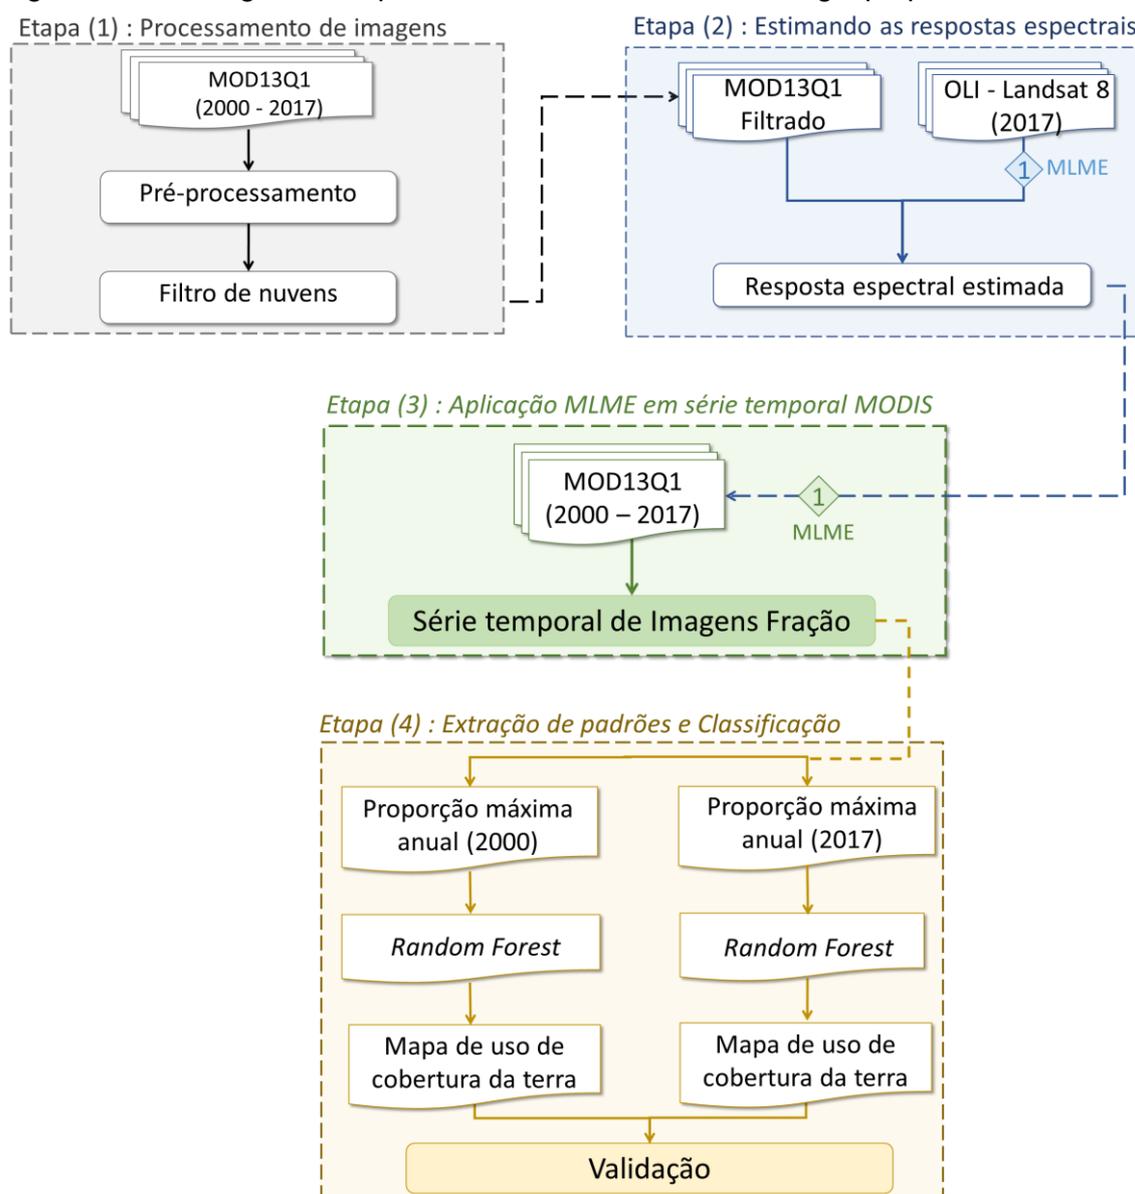
4.4 Métodos

O fluxograma apresentado na Figura 4.6 representa simplificadaamente as etapas gerais de execução deste trabalho para atingir os objetivos propostos. Todas as etapas serão descritas detalhadamente nos próximos tópicos.

De modo geral, foram realizados os pré-processamentos dos dados MODIS e o processamento das imagens para atingir os objetivos específicos: 1.1) Adquirir todas as imagens provenientes do sensor MODIS, do produto MOD13Q1 para o período entre 2000 e 2017; 1.2) Realizar o pré-processamento das imagens adquiridas; 1.3) utilizar o dado de qualidade do produto MOD13Q1 para

produção de um filtro de nuvens; 2) estimar os *endmembers* (*pixels* puros) a partir das imagens de melhor resolução espacial do OLI/Landsat 8 para aplicação do Modelo Linear de Mistura Espectral (MLME) nos produtos provenientes do sensor MODIS; 3) gerar uma série temporal de imagens fração derivadas do MLME nos produtos provenientes do sensor MODIS para o período entre 2000 e 2017, utilizando os *endmembers* estimados na fase anterior; 4.1) gerar mosaicos das imagens fração calculando o valor máximo anual das proporções dos componentes para os anos de 2000 e 2017; 4.2) gerar dois mapas temáticos de uso e cobertura da terra no estado da Bahia em 2000 e 2017 utilizando os mosaicos gerados na fase anterior, aplicando o classificador *Random Forest*; 4.3) avaliar as acurácias dos mapas temáticos de uso e cobertura da terra obtidos; 5) analisar qualitativamente os perfis temporais das imagens fração obtidas para o período entre 2000 a 2017.

Figura 4.6 – Fluxograma simplificado descrevendo a metodologia proposta.



Fonte: Produção do autor.

4.5 Processamento de imagens

4.5.1 Pré-processamento de imagens MODIS

Os dados MODIS são disponibilizados no formato HDF (*"Hierarchy Data Format"*), com um nível de quantização de 16 bits, nas projeções Integerized Sinusoidal. Por este não ser um formato muito usual nos SIGs geralmente utilizados para o processamento de imagens, um programa denominado MRT

(*MODIS Reprojection Tool*) é disponibilizado gratuitamente no endereço eletrônico (https://lpdaac.usgs.gov/tools/modis_reprojection_tool). Com este programa é possível realizar o processamento de imagens MODIS alterando a projeção, conversão para formatos mais comumente utilizados e geração de mosaicos dos *tiles* obtidos (ARAGÃO; ARAI; SHIMABUKURO, 2009).

Nesta dissertação, devido à grande quantidade de imagens obtidas, o pré-processamento foi realizado por meio de uma seleção automática dos parâmetros de entrada utilizados no MRT. Desta forma, foram selecionadas a projeção Geográfica, devido à rapidez nos processamentos subsequentes, o formato GeoTIFF e a opção de mosaico dos *tiles*. Com estes parâmetros de entrada, um arquivo lista foi gerado utilizando o MRT, que foi, então, executado em *prompt* de comando (no sistema operacional Windows) e aplicado à todas as imagens obtidas.

4.6 Filtro de nuvem

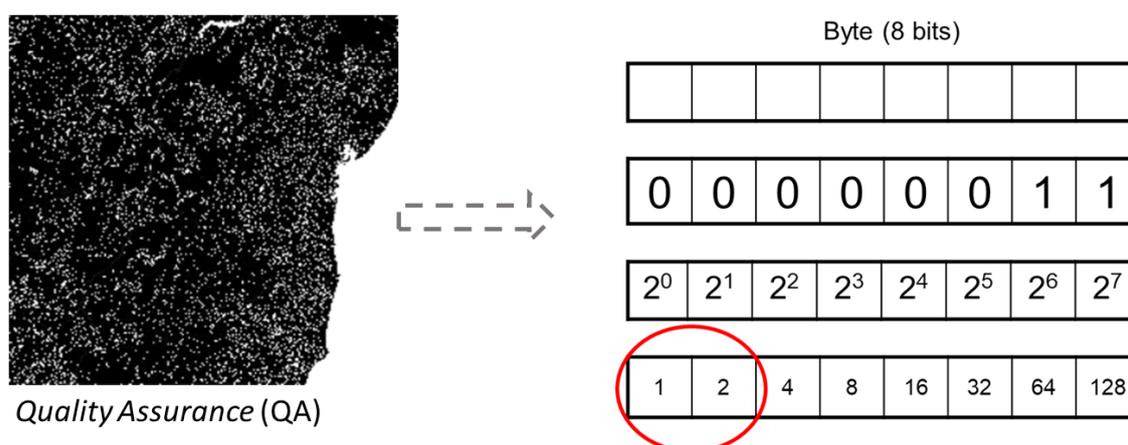
A ausência de nuvens em imagens de Sensoriamento Remoto é fundamental para o mapeamento e monitoramento da cobertura da terra (RUDORFF et al., 2010). Isso ocorre devido à presença de ruídos que podem causar alterações nos valores de reflectância, impedindo análises e resultados com maior exatidão (LU et al., 2007).

Para as imagens MODIS do produto MOD13Q1, além das correções atmosféricas e geométricas já presentes dos dados disponibilizados, a garantia de qualidade dos *pixels* é disponibilizada em imagens que fornecem informações significativas *pixel a pixel* sobre as condições do dado produzido, denominada *Quality Assurance* (QA). A utilização do QA permite, assim, a análise, seleção ou triagem dos dados (DIDAN et al., 2015).

O QA é apresentado em valores numéricos (bit) que resumem a qualidade do *pixel*. Um bit só pode assumir valores binários, ou seja, 0 e 1 e, assim, as combinações de 8 bits formam 1 Byte. Considerando apenas os dois primeiros bits contidos no QA (Figura 4.7), juntos, eles fornecem quatro diferentes combinações (00, 01, 10 e 11) que correspondem a um determinado tipo de

condição do *pixel*. Essas quatro diferentes combinações podem ser descritas em: *pixel* produzido com boa qualidade, *pixel* produzido com qualidade duvidosa, *pixel* com provável incidência de nuvens e *pixel* não produzido (Tabela 4.5).

Figura 4.7 – Exemplo de seleção dos bits utilizados na imagem QA do produto MOD13Q1.



Fonte: Produção do autor.

Tabela 4.5 – Descrição da imagem *VI Quality* do produto MOD13Q1.

Bit	Parâmetro	Valor	Descrição
0-1	Qualidade do IV	00	IV produzido com boa qualidade
		01	IV produzido com qualidade duvidosa
		10	<i>Pixel</i> produzido, porém, provavelmente com nuvens
		11	<i>Pixel</i> não produzido

Fonte: Adaptado de Didan et al. (2015).

De forma a obter dados com maior qualidade e confiabilidade, para esta dissertação foi implementada a filtragem de *pixels* utilizando o QA a partir da identificação de *pixels* falhos (presença de nuvens) para todo o período de aquisição das imagens. Assim, de modo a assegurar estimativas válidas nos valores de reflectância em toda a série temporal, testes foram realizados em dois cenários: (1) utilizando apenas *pixels* produzidos com boa qualidade (00); (2) adicionando *pixels* com qualidade duvidosa (01).

Parte da metodologia proposta nesta dissertação foi realizada com os dois cenários de modo a conhecer qual apresentaria os melhores resultados. Deste modo, mesmo utilizando uma abordagem multitemporal, observou-se que o cenário (1) apresentou muitas áreas filtradas na classificação final, ou seja, sem valores de reflectância, demonstrando que nessas áreas não foram detectados *pixels* com boa qualidade ao menos uma vez ao ano. Dessa forma, prosseguiu-se com a utilização do cenário (2), pelo qual foi possível obter valores para todos os *pixels* ao menos uma vez ao ano e, ao mesmo tempo, assegurar a menor incidência de nuvens possíveis aos dados utilizados.

4.7 Seleção de *endmembers* e aplicação do MLME

Uma relação linear é utilizada para representar a mistura espectral dos componentes contidos dentro do *pixel*, ou seja, o MLME assume que a reflectância espectral de um *pixel* pode ser obtida como uma combinação linear das respostas de cada componente assumido como referência. Dessa forma, cada *pixel* contém informações sobre a proporção e a resposta espectral de cada componente (SHIMABUKURO; SMITH, 1995).

Admitindo esta abordagem, entende-se então que conhecendo as respostas espectrais de cada componente de referência, as suas proporções no *pixel* podem ser obtidas. Assim, o modelo linear de mistura espectral proposto por Shimabukuro e Smith (1991) pode ser representado genericamente como:

$$R_i = \Sigma (a_{ij}x_{j1}) + \varepsilon_i \quad (2.1)$$

Onde:

r_i = reflectância média espectral na banda espectral i ;

a_{ij} = resposta espectral da componente j da mistura na banda espectral i ;

x_j = proporção componente j em um pixel;

ε_i = erro na banda espectral i ;

$i = 1, n$ (número de bandas espectrais utilizadas);

$j = 1, m$ (número de componentes considerados).

O resultado da equação (2.1) está sujeito a duas restrições, que devem ser atendidas com o somatório das proporções igual a um e valores não negativos:

$$\sum x_j = 1 \tag{2.2}$$

$$0 \leq x_j \leq 1$$

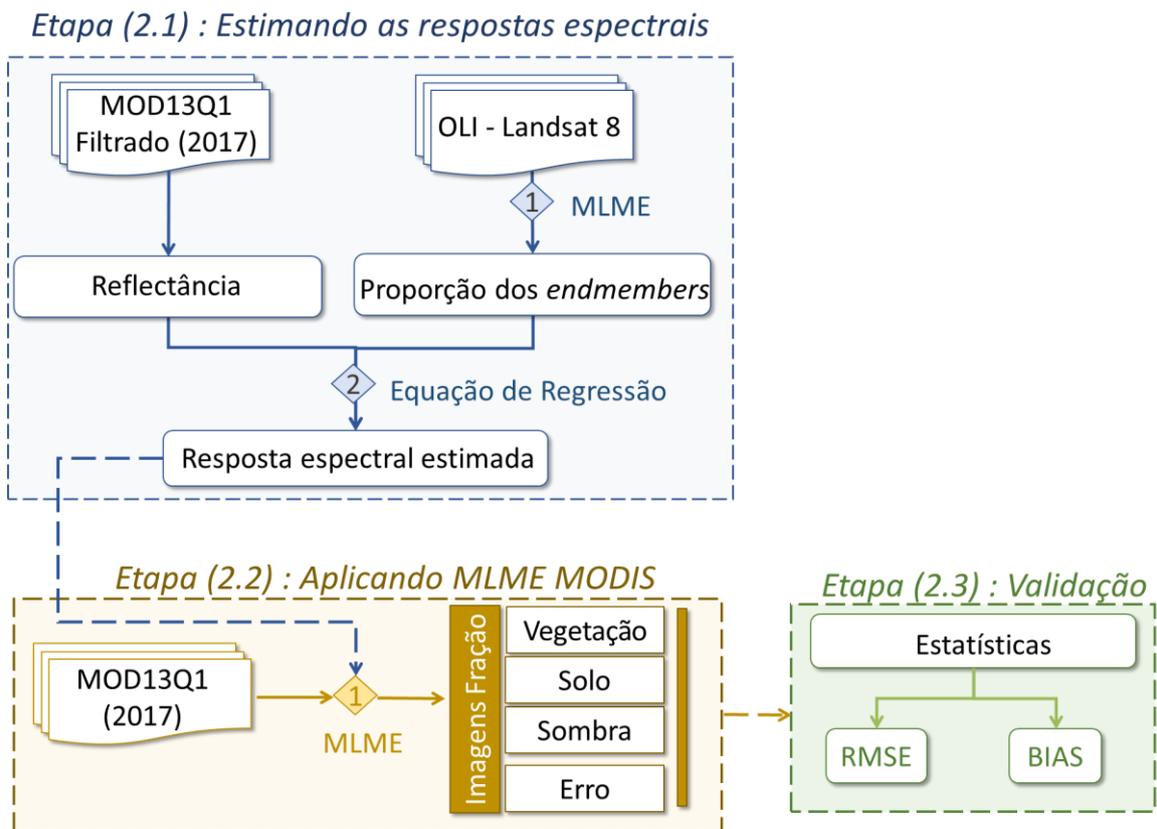
Entretanto, para esta dissertação diversos limiares de restrição foram testados e, por fim, optou-se por não restringir os dados visto que este procedimento exige maior processamento computacional. Além disso, os resultados finais não apresentaram diferenças nas acurácias das classificações finais.

Diante deste contexto, foi aplicada uma abordagem multisensor utilizando o MLME para explorar a combinação de imagens de diferentes resoluções espaciais e, então, estender as informações contidas nas imagens fração em escala local para áreas mais extensas. Assim, foi visado estimar as respostas espectrais dos *endmembers* em imagens de baixa resolução espacial (MODIS), a partir das proporções estimadas nas imagens de maior resolução espacial (OLI/Landsat 8) (Figura 4.8), como avaliado por Dutra et al. (2018; 2019a).

Detalhadamente como etapa (2.1) (Figura 4.8) do fluxograma geral (Figura 4.6), uma cena OLI/Landsat com data de imageamento próxima a uma cena MODIS foi utilizada e aplicado o MLME para estimar as proporções de cada componente a partir da reflectância espectral disponível na própria imagem em

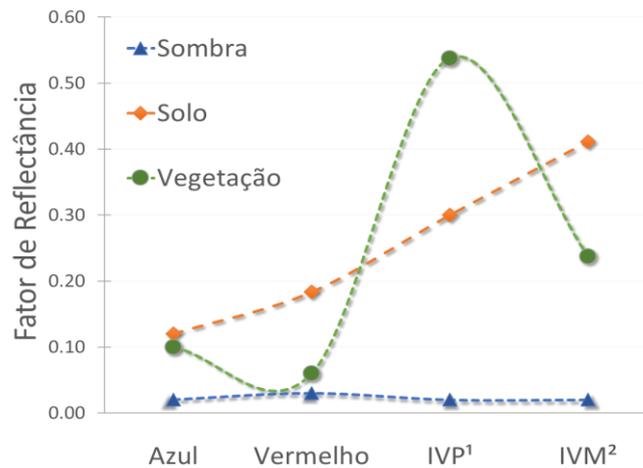
estudo. Empregando a abordagem de *pixels* puros selecionados em função da resposta espectral, foram considerados três componentes de referência no *pixel* correspondentes à vegetação, solo e sombra (Figura 4.9). Como resultado do MLME para essa primeira etapa, foram obtidas as imagens fração para cada componente considerado no *pixel* apenas para uma única cena OLI/Landsat.

Figura 4.8 – Fluxograma metodológico descrevendo a etapa de estimativa dos *endmembers*.



Fonte: Produção do autor.

Figura 4.9 – Resposta espectral dos componentes de referência obtidos na imagem em estudo. Sendo, IVP¹ - Infravermelho Próximo; IVM² - Infravermelho Médio.



Fonte: Produção do autor.

Posteriormente, admitindo que as proporções (x_j) dos componentes extraídos das imagens fração derivadas do MLME aplicado à cena OLI/Landsat são conhecidas, neste trabalho adotou-se o modelo matemático proposto por Richardson et al. (1975) para estimar a resposta espectral dos componentes que serão aplicadas na cena MODIS. O modelo foi desenvolvido para particionar a reflectância espectral (r_i) em reflectâncias espectrais dos componentes (a_{ij}), em que $j = 1$ representa a componente sombra, $j = 2$ representa a componente vegetação e $j = 3$ representa o componente solo. O modelo pode ser escrito como:

$$r_i = a_{i1}x_1 + a_{i2}x_2 + a_{i3}(1 - x_1 - x_2) \quad (4.1)$$

Onde:

r_i = reflectância espectral média em todas as bandas espectrais;

a_{ij} = reflectância espectral dos componentes a serem estimados;

i = faixas espectrais do sensor utilizado;

j = componentes estabelecidos, sendo vegetação (1), solo (2) e sombra (3);

x_j = proporções conhecidas dos componentes de referência;

Rescrevendo a equação acima, temos:

$$r_i = a_{i3} + (a_{i1} - a_{i3}) x_1 + (a_{i2} - a_{i3}) x_2, \quad (4.2)$$

Similar a equação de regressão linear múltipla:

$$r_i = A_0 + A_1 x_1 + A_2 x_2 \quad (4.3)$$

Assim, uma vez que foram obtidas as proporções na cena OLI/Landsat, elas se tornam as variáveis de entrada na equação (4.3) juntamente com a reflectância espectral média em todas as faixas espectrais da cena MODIS. Assim, a combinação entre os produtos com diferentes resoluções espaciais foi possível determinar a resposta espectral dos componentes com o resultados obtidos da regressão, onde: sombra (A_0), vegetação ($A_0 + A_1$) e solo ($A_0 + A_2$). Assumindo que somatório do MLME deve ser igual a um, neste caso não se torna necessária a adição da proporção sombra como parâmetro de entrada do modelo.

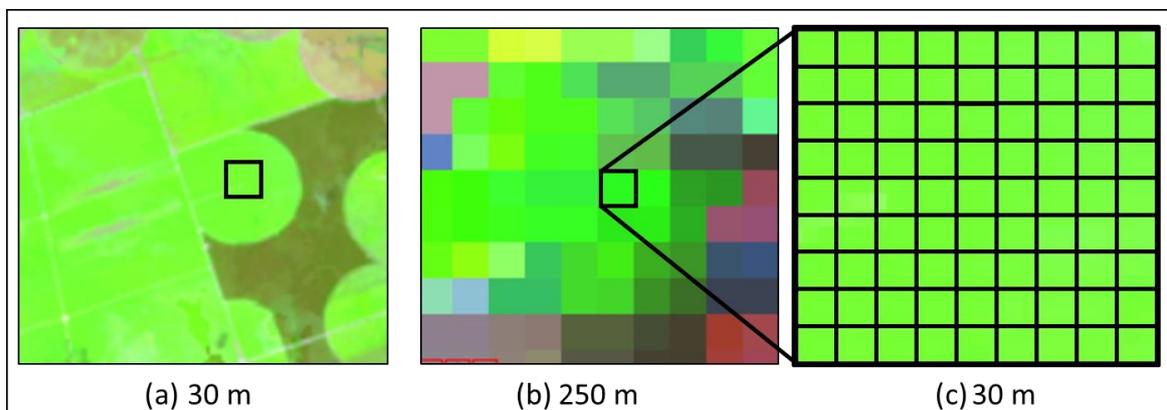
Das faixas espectrais utilizadas para este fim, foram adotadas o infravermelho médio, infravermelho próximo e vermelho para a composição RGB. Como observado nas Tabelas 4.1 a 4.3, pequenas diferenças são observadas na abrangência das faixas espectrais do sensor MODIS quando comparado aos sensores Landsat, tendo este último maior largura nas faixas utilizadas. Assim, a partir de cada faixa espectral das imagens MODIS e suas respectivas proporções nas imagens fração OLI/Landsat 8, foi calculado o coeficiente de determinação (r^2) por regressão linear múltipla (Equação 4.3). O r^2 é calculado como uma das formas de avaliar a qualidade de ajuste modelo obtido, representado por:

$$r^2 = \frac{\sum_{i=1}^N (\hat{X}_i - \bar{X}_i)}{\sum_{i=1}^N (\hat{X}_i - \bar{X}_i)^2}$$

onde \hat{X}_i é a proporção estimada a partir das imagens fração OLI/Landsat, \bar{X}_i é o valor correspondente ao fator de reflectância espectral no sensor MODIS em cada unidade amostral.

Assim, para esta etapa, foram coletadas 25 amostras para um único período na área de estudo, com as mesmas coordenadas geográficas em ambos os produtos e sem a incidência de nuvens (FAN; DENG, 2014). Para isto, foi considerado que um *pixel* do produto de 250 m corresponde a 81 *pixels* no produto de 30 m (Figura 4.10).

Figura 4.10 - Representação da composição de um pixel em diferentes resoluções espaciais, exibindo a visão geral em imagem de 30 m (a) e em detalhe um pixel em 250 m (MODIS) (b) e em 30 m (Landsat 8).



Fonte: Produção do autor.

Na etapa (2.2), utilizando a resposta espectral estimada dos componentes vegetação, solo e sombra obtidos da etapa anterior, o MLME foi aplicado às imagens MODIS. Para fins comparativos, o MLME também foi aplicado ao mesmo produto utilizando a resposta espectral dos componentes de referência adquiridos na própria imagem – abordagem convencional.

O desempenho do método utilizando as imagens fração foi avaliado de duas maneiras (Etapa 2.3): (1) comparando quantitativamente as imagens fração da vegetação, solo, sombra e erro obtidos pelo MLME nas duas abordagens e (2) comparando espacialmente e qualitativamente as imagens fração. As imagens erro também são geradas com a aplicação do MLME e informam sobre a acurácia dos modelos empregados em valores de 0 a 1. Assim, as imagens erro apresentarão valores inferiores quanto menor a confusão entre os parâmetros de entrada.

Além disso o RMSE, que representa o erro quadrático médio, e o BIAS, que indica a tendência positiva ou negativa do erro, foram utilizados para avaliar a precisão dos resultados obtidos, sendo expressos da seguinte maneira:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{X}_i - X_i)^2}{N}}$$

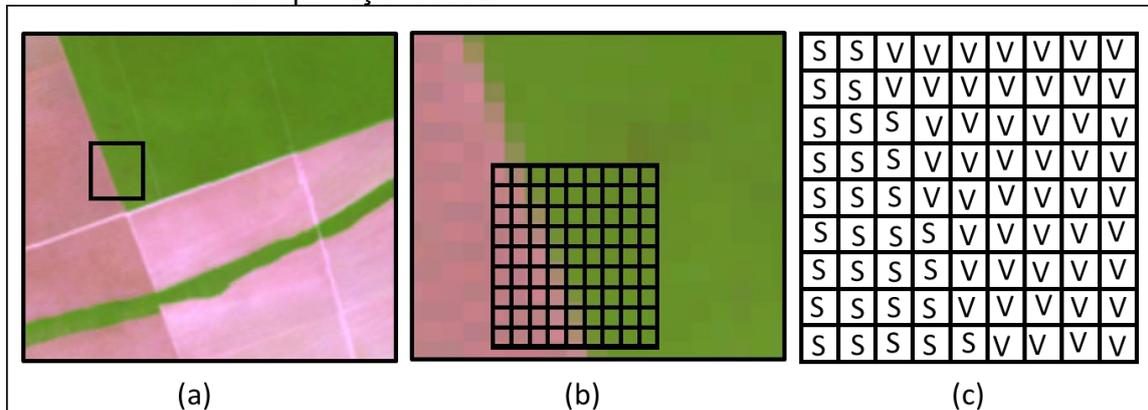
$$BIAS = \sum_{i=1}^N (\hat{X}_i - X_i)^2$$

onde \hat{X}_i é a proporção estimada de cada alvo i obtida a partir das imagens fração MODIS, X_i é a proporção correspondente a cada alvo i extraídas visualmente nas imagens de referência OLI/Landsat 8; e N é o número total das amostras coletadas.

Para isto, O RMSE dos alvos selecionados para a geração do MLME foi calculado utilizando 30 amostras nas imagens fração resultantes do MODIS e na imagem Landsat. As amostras foram selecionadas por amostragem aleatória com a dimensão de 250 m por 250 m. Para cada amostra, os *pixels* contendo áreas de vegetação e solo são contabilizados e, então, a proporção de área é calculada por interpretação visual dividindo o total de *pixels* de cada alvo pelo total de *pixels* da área de amostragem (Figura 4.11) (FAN; DENG, 2014). Desta avaliação não foram contabilizadas as áreas que representam o alvo sombra, pois a existência de *pixels* duvidosos pode influenciar nos valores

de proporção da fração sombra, sendo também variável entre as imagens dos diferentes sensores.

Figura 4.11 – Representação da proporção de cada amostra calculada por interpretação visual.



Onde: (a) detalhe na imagem OLI/Landsat 8 representando áreas de solo exposto e vegetação em uma área amostral selecionada por amostragem aleatória, (b) detalhe exibindo o número de *pixels* na imagem OLI/Landsat representando um *pixel* na imagem MODIS, (c) representação da classificação visual dos *pixels* na imagem OLI/Landsat 8, sendo o alvo solo representado por “S” e o alvo vegetação representado por “V”.

Fonte: Produção do autor.

Considerando esta abordagem *pixel a pixel*, uma análise preliminar foi realizada de modo a observar se havia o deslocamento de *pixels* entre as imagens MODIS e OLI/Landsat. Para isto, uma reamostragem dos *pixels* OLI/Landsat para $0,002245^\circ$, equivalente ao mesmo tamanho de um *pixel* MODIS, foi aplicada e, posteriormente, comparada entre ambas as imagens de modo a assumir o correto posicionamento entre as imagens para validação.

4.8 Aplicação multitemporal do MLME

As imagens fração podem ser usadas para mapeamento devido às seguintes características: a) a imagem fração vegetação destaca as condições de cobertura da vegetação de modo similar aos índices de vegetação como o NDVI (*Normalized Difference Vegetation Index*) e o EVI (*Enhanced Vegetation Index*), permitindo diferenciar as áreas florestadas de áreas agrícolas, considerando que esta última apresenta elevado vigor vegetativo e, conseqüentemente, elevada reflectância no infravermelho próximo; b) a imagem fração sombra destaca áreas com baixos valores de reflectância, como a água; e c) a imagem fração solo destaca áreas com altos valores de reflectância no infravermelho próximo e infravermelho médio, como solo exposto e áreas desmatadas, sendo que áreas florestadas tendem a apresentar menor proporção de solo dentro do *pixel* ou apresentarem efeitos sazonais na proporção de solo.

A partir da definição dos *endmembers* obtidos da etapa anterior, o MLME foi aplicado para toda a série temporal correspondente ao período de 2000 a 2017, nas bandas do produto MOD13Q1. Para isto, assumindo que as imagens adquiridas são corrigidas atmosféricamente, calibradas e que não há mudanças radiométricas significativas ao longo da série temporal, partiu-se da hipótese de que os valores de reflectância encontrados para um *pixel* puro serão existentes para todo o período, tendo a sua variação na proporção estimada dos alvos como consequência devido à influência da sazonalidade, mudanças antrópicas e climáticas. Desta maneira, é possível gerar um modelo “único” aplicado à toda série temporal que permita a comparação das mudanças ao longo de todo período.

Para a geração dos mapas base referentes aos anos de 2000 e 2017 utilizando as imagens fração obtidas das imagens MODIS, uma nova abordagem foi aplicada para calcular a proporção máxima das imagens fração em ambos os anos, como proposta por Dutra et al. (2019b). Esta etapa consistiu na análise temporal de cada imagem fração gerada nas composições de 16 dias existentes em 2000 e em 2017.

Diante do exposto, a partir das imagens fração obtidas anteriormente, foram geradas composições contendo, em cada ano e para cada *pixel*:

- (i) O máximo valor da proporção no conjunto de imagens multitemporais da fração vegetação;
- (ii) O máximo valor da proporção no conjunto de imagens multitemporais da fração sombra/água;
- (iii) O máximo valor da proporção no conjunto de imagens multitemporais da fração solo;

Para este processo, partiu-se das hipóteses de que: 1) na Bahia existem diferentes tipologias climáticas e que, dessa forma, não há um único período seco e único período úmido que contemple todo o estado; 2) quanto maior a quantidade de imagens utilizadas, maior seria a probabilidade de encontrar *pixels* sem incidência de nuvens; e 3) menor seria a influência da sazonalidade da vegetação nativa e diferenças entre os períodos de colheita e preparo do solo em áreas agrícolas.

Toda a etapa de aplicação do MLME foi realizada em linguagem *Interactive Data Language* (IDL), utilizando um programa com funcionalidades implementadas em ambiente *Environment for Visualizing Images* (ENVI).

4.9 Classificação por *Random Forest*

4.9.1 Seleção de amostras

Para a filtragem dos polígonos de mapeamentos oficiais e seleção de amostras para as outras classes adotadas na classificação, foram utilizados os mosaicos Landsat e imagens de alta resolução com datas próximas disponíveis no *Google Earth* para interpretação visual. Com isto, foram gerados 893 polígonos, abrangendo uma área total de 29.013 km² (Tabela 4.6). A cada um destes polígonos foi atribuído um rótulo de classe, obtendo a legenda: Vegetação nativa (subdividida em Caatinga, Cerrado, Mata Atlântica), Agricultura, Solo, Pastagem e Corpos hídricos.

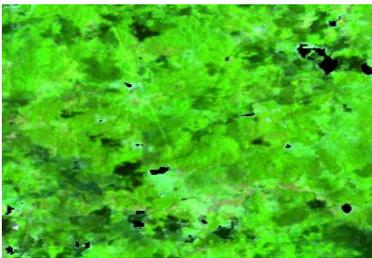
Tabela 4.6 – Polígonos coletados em cada classe de uso e cobertura da terra.

Sigla	Classe	Área total dos polígonos (km²)
CA	Caatinga	17.699,88
CE	Cerrado	4.238,60
MA	Mata Atlântica	5.265,22
AG	Agricultura	637,15
PA	Pastagem	694,66
SO	Solo	26,29
CH	Corpos hídricos	451,50
	Total	29.013,33

Fonte: Produção do autor.

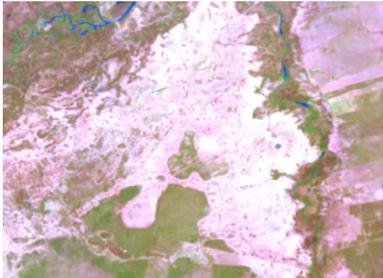
A Tabela 4.7 exibe a descrição das classes de uso e cobertura da terra identificadas com as imagens Landsat e *Google Earth*. Para as classes de vegetação nativa na Caatinga, Cerrado e Mata Atlântica, foram consideradas todas as fitofisionomias inseridas nestes domínios, desde as fitofisionomias florestadas até mosaicos de formações campestres. Assim, para esta dissertação foram consideradas apenas a legenda de formação e não sub-formação das fitofisionomias da vegetação.

Tabela 4.7 – Classes de uso e cobertura adotadas no estado da Bahia.

Sigla	Classe	Imagem Landsat	Imagem Google Earth
CA	Caatinga		
CE	Cerrado		
MA	Mata Atlântica		
AG	Agricultura		

continua

Tabela 4.7 – Conclusão.

PA	Pastagem		
SO	Solo		
CH	Corpos Hídricos		

Fonte: Produção do autor.

4.9.2 Classificador

Nesta etapa foram utilizadas como variáveis de entrada no classificador RF (LIAW; WIENER, 2002) as imagens fração contendo as máximas proporções de vegetação, solo e sombra em seus respectivos anos 2000 e 2017, no *software* R versão 3.3.2 (R CORE TEAM, 2018).

Um dos parâmetros de entrada no modelo é o número de árvores a serem geradas (*Ntree*). Para isto, devido à estabilização de erros do modelo ocorrer antes de atingir o *Ntree* igual a 500 (LAWRENCE et al., 2006), muitos trabalhos e pacotes desenvolvidos para aplicação do classificador utilizam *Ntree* igual a

500 como valor padrão. Desta forma, foram definidos o número de árvores de decisão (*NTree*) igual a 500, estabelecido como *default* no pacote utilizado.

Diante do elevado número de polígonos obtidos para determinadas classes, alguns testes foram realizados variando o número de *pixels* utilizados para o treinamento do classificador, como, por exemplo, 100.000, 50.000 e 10.000 *pixels*. Entretanto, classes com menor número de áreas amostrais foram subestimadas quando utilizado o maior número de *pixels* na classificação, optando, assim, pela utilização de 50.000 *pixels* aleatórios em cada classe para treinamento. Além disso, um grande número de amostras exige maior nível de processamento dos dados. Também é possível gerar um gráfico de dispersão de pontos amostrais exibindo a influência de cada variável de entrada e os padrões para cada classe que serão utilizadas como treinamento para a aplicação no classificador.

4.9.3 Validação dos resultados

A acurácia da classificação foi avaliada por abordagem baseada em Olofsson et al. (2014), conforme indicado pela FAO (2016). Esta abordagem se baseia no delineamento amostral estratificado, que considera a proporção de cada classe com base na frequência de *pixels*. Assim, uma matriz de confusão é gerada com base nas proporções estimadas.

Para isto, o desenho amostral foi implementado considerando cada estrato de acordo com as sete classes consideradas neste trabalho (Caatinga, Cerrado, Mata Atlântica, Agricultura, Pastagem, Solo e Corpos Hídricos). Todos os 1592 pontos de amostragem obtidos aleatoriamente e a análise dos resultados foram realizadas em ambiente de programação R e algoritmos disponibilizados em (<https://github.com/openforis/accuracy-assessment>). Neste processo, as mesmas imagens orbitais do sensor Landsat utilizadas para coleta de amostras e polígonos utilizados como entrada no classificador foram utilizados para interpretação visual dos pontos amostrais.

Olofsson et al. (2014) indicam a utilização de uma matriz de confusão ponderando a área amostrada pela área total da classe (com base nas proporções de cada classe) (equação 4.5). A partir desta matriz, o intervalo de confiança de 95% é obtido com o cálculo do erro padrão (equação 4.6) e também são calculadas a acurácia global (equação 4.7), a acurácia do produtor (equação 4.8) ou erro de omissão e a acurácia do usuário (equação 4.8) ou erro de comissão.

$$\hat{p}_{i,j} = \frac{W_i \times n_{ij}}{n_i} \quad (4.5)$$

\hat{p}_{ij} – proporção de área amostral estimada para cada classe;

W_i – peso da classe (proporção da área classificada como classe i e que pode ser calculada dividindo-se o número total de *pixels* por classe;

n_{ij} – contagem absoluta do número de *pixels* que tem na imagem classificada i e na classe de referência j .

$$S(\hat{p}) = \sqrt{\sum_i \frac{W_i \hat{p}_{i,j} - \hat{p}_{i,j}^2}{n_i - 1}} \quad (4.6)$$

Sendo $S(\hat{p})$ a variância estimada para a acurácia global.

$$A = \sum_{i=1}^q \hat{p}_{ij} \quad (4.7)$$

$$P_j = \frac{p_{ij}}{p_j} \quad (4.8)$$

$$U_i = \frac{p_{ij}}{p_j} \quad (4.9)$$

Onde A representa a proporção de *pixels* classificados corretamente; P_j representa a acurácia do produtor para a classe j , ou seja, a proporção de uma classe j na imagem de referência que é mapeada como classe j na imagem classificada; e U_i representa a acurácia do usuário para a classe i , ou seja, a proporção de uma classe i mapeada como classe i e que está contida na imagem de referência como classe i , e q é o número de classes.

4.10 Perfis temporais das imagens fração

Um grande número de estudos tem se baseado em análises de séries temporais a partir de amostras de *pixels* selecionadas ao longo de um determinado período no tempo (GALFORD et al., 2008; COUTO Jr. et al., 2012). Entretanto, séries temporais geralmente apresentam grande quantidade de dados, sendo indicado o uso de técnicas que reduzem a sua dimensionalidade, sem perdas significativas de informações (BORGES; SANO, 2014).

Desta maneira, obtidas as imagens fração para todo o período entre 2000 e 2017, é possível observar a proporção de cada alvo, *pixel a pixel*, na série temporal em estudo. Para isto, foram geradas coleções de arquivos (*stack*) contendo todas as imagens fração para cada alvo, de modo a gerar um *stack* das imagens fração vegetação, um *stack* das imagens fração solo e, por fim, um *stack* das imagens fração sombra.

Com este conjunto de dados multitemporais, foram construídos perfis dos quais foram extraídos valores de cada *pixel* selecionado na imagem. Os perfis foram construídos em linguagem IDL (*Interactive Data Language*) no ambiente ENVI, que permite a plotagem de séries espaço-temporais desde que os arquivos ocupem a mesma área geográfica e bandas regulares, que, para este trabalho, foram representadas pelo conjunto de coleções das imagens fração.

A geração de perfis com dados multitemporais das imagens fração ainda não foi encontrada na literatura, sendo, portanto, uma contribuição desta dissertação.

5 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados e discutidos os resultados obtidos nesta dissertação. Inicialmente são expostos os resultados referentes aos *endmembers* estimados para a geração de imagens fração no MODIS. Em seguida, são apresentados os resultados obtidos para os mapas base de uso e cobertura da terra para o estado da Bahia em 2000 e 2017, e, por fim, são apresentados os perfis temporais das imagens fração obtidos para o monitoramento da vegetação.

5.1 Estimando *endmembers*

Aplicando a metodologia apresentada na Seção 4.5, foram obtidas as equações e o coeficiente de determinação em cada faixa espectral adotada, apresentados na Tabela 5.1 e Figura 5.1.

Tabela 5.1 – Coeficiente de determinação e equação obtida por regressão linear múltipla.

Faixas espectrais	Equação	r ² (N =25)
Azul	$r_i = 0,115 + 0,00433x + 0,0418x_2$	0,59
Vermelho	$r_i = 0,106 - 0,00265x + 0,481x_2$	0,87
IVP ¹	$r_i = -0,119 + 0,949x + 0,532x_2$	0,78
IVM ²	$r_i = 0,192 + 0,147x + 0,587x_2$	0,80

¹ IVP - Infravermelho Próximo; ² IVM - Infravermelho Médio.

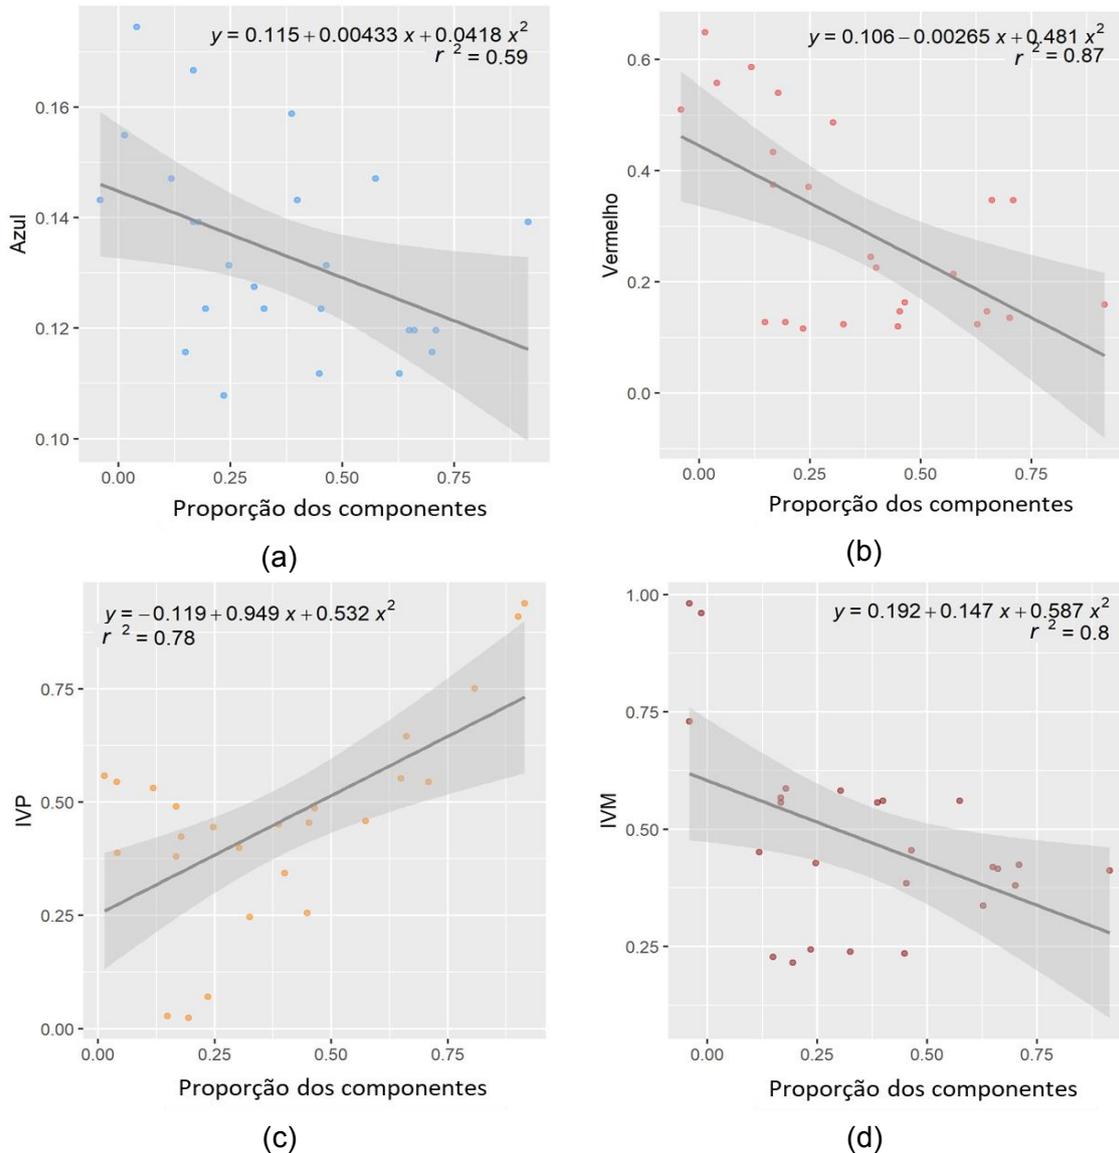
Fonte: Produção do autor.

Observando os gráficos de linha ajustada, os pontos geralmente seguem a linha de regressão especialmente nas faixas espectrais do Vermelho, IVP e IVM. Como era esperado, as equações obtidas demonstram a relação entre os componentes de referência, ou seja, enquanto a componente sombra (A_o) apresenta os valores mais inferiores na equação, a componente vegetação ($A_o + A_1$) apresenta a redução na faixa do vermelho, pico na faixa do IVP e

decréscimo novamente na faixa do IVM. De maneira inversa, a componente solo ($A_0 + A_2$) apresenta crescimento constante ao longo das faixas espectrais.

O coeficiente de determinação obtido em cada faixa espectral representa o quanto se consegue explicar a variação na proporção dos componentes em função da variação nas faixas espectrais, ou seja, mostra se o modelo obtido é adequado. Nesta pesquisa, os valores elevados de r^2 demonstram que o modelo obtido foi bem ajustado, exceto pela faixa espectral do Azul, que obteve r^2 de 0,59. Este resultado pode estar relacionado ao uso apenas das proporções dos componentes vegetação e solo para a obtenção das equações, além de ser a faixa mais sensível à ruídos, que podem variar entre os sensores.

Figura 5.1 – Equação obtida com a regressão linear múltipla para cada faixa espectral e seus respectivos coeficientes de determinação (r^2).



Onde: faixa espectral do Azul (a), Vermelho (b), IVP (c) e IVM (d).

Fonte: Produção do autor.

As respostas espectrais estimadas para determinação dos *endmembers* nas imagens MODIS estão apresentados na Tabela 5.2. Comparando a resposta espectral dos alvos analisados neste estudo, como esperado e discutido anteriormente, observa-se que as respostas espectrais foram similares à curva espectral teórica dos alvos em questão.

Tabela 5.2 – Fator de reflectância dos componentes estimados utilizando a combinação de diferentes sensores e resoluções espaciais.

Ano 2017				
Faixas Espectrais				
Endmembers	Azul	Vermelho	IVP¹	IVM²
Sombra	0,03	0,02	0,12	0,02
Solo	0,13	0,20	0,35	0,47
Vegetação	0,02	0,04	0,66	0,25

IVP¹ - Infravermelho Próximo; IVM² - Infravermelho Médio.

Fonte: Produção do autor.

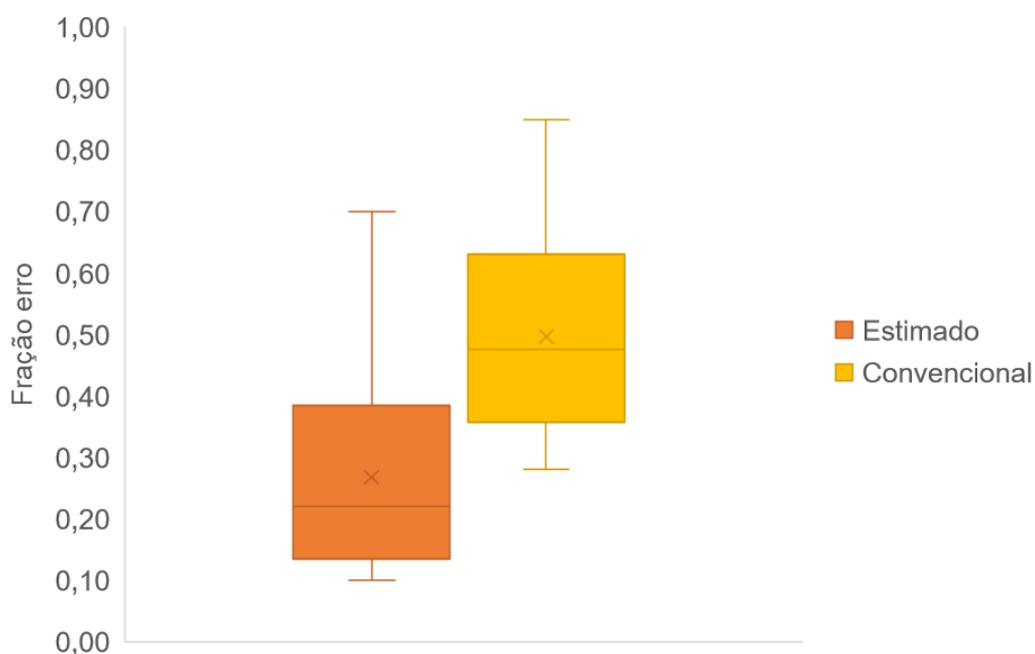
Como primeiro método de avaliação do desempenho do MLME para estimar às respostas espectrais dos *endmembers* em imagens de moderada resolução espacial a partir das proporções estimadas nas imagens de média resolução espacial, foi realizada a comparação das médias obtidas das imagens erro geradas por esta abordagem (MLME_{ES}) e entre a abordagem convencional (MLME_{CO}) foi realizada (Tabela 5.3) (Figura 5.2).

Tabela 5.3 – Média das amostras geradas da fração erro do MLME onde estimado e convencional correspondem à resolução espacial de 250 m.

	MLME_{ES}	MLME_{CO}
Imagem fração erro (\bar{X})	0,27	0,46

Fonte: Produção do autor.

Figura 5.2 – Média e desvio padrão das amostras geradas da fração erro do MLME onde estimado e convencional correspondem à resolução espacial de 250 m.



Fonte: Produção do autor.

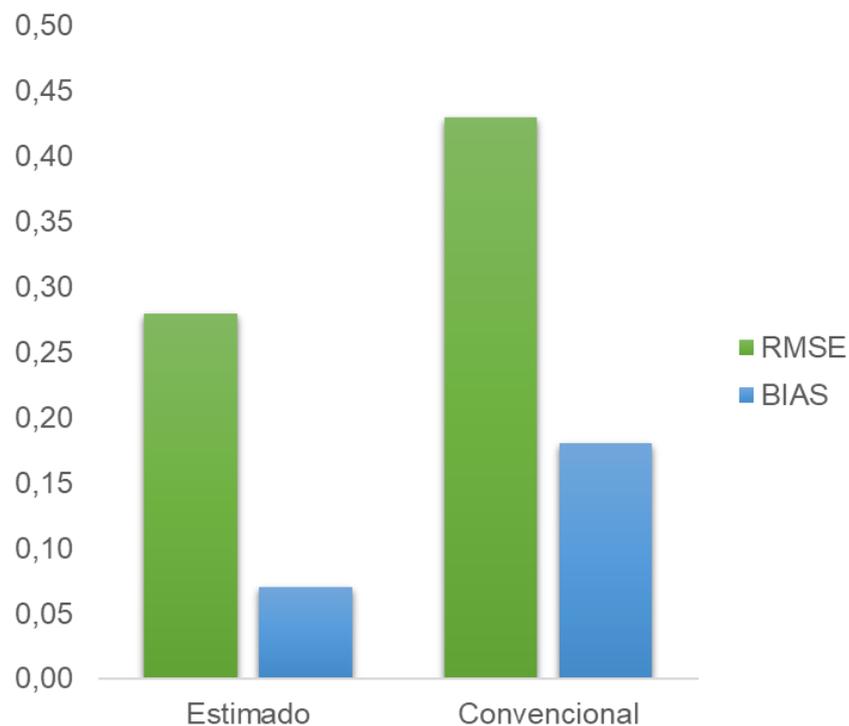
As frações erro normalmente apresentam valores inferiores de acordo com a acurácia dos modelos empregados. Neste sentido, o erro médio obtido por MLME_{ES} foi inferior (0,27) àquele obtido por MLME_{CO} (0,46) no período de análise. Entretanto, ressalta-se que o erro médio também está associado ao fato de que outros componentes podem estar contidos no *pixel* e, assim, o número de componentes definidos neste trabalho pode não ser o suficiente para o modelo utilizado em determinadas áreas do estado da Bahia, o que justifica os valores mais elevados em desvio padrão por ambas as abordagens.

Observando os valores do RMSE (Figura 5.3), o MLME_{ES} apresentou valores mais próximos de 0, resultando no RMSE de aproximadamente 0,28, enquanto o MLME_{CO} obteve RMSE de aproximadamente 0,43, o que demonstra maior acurácia do modelo quando estimada a resposta espectral dos alvos.

O BIAS mede a tendência de o modelo superestimar ou subestimar a resposta espectral em relação ao observado. Assim, observa-se que ambas as

abordagens apresentaram tendência positiva, ou seja, tanto o $MLME_{ES}$ quanto o $MLME_{CO}$ superestimam a resposta espectral dos alvos, o que pode estar relacionado à moderada resolução espacial do sensor MODIS. Entretanto, o $MLME_{CO}$ apresentou maior superestimativa (0,18) em relação ao $MLME_{ES}$ (0,07).

Figura 5.3 – RMSE e BIAS das amostras geradas sendo que estimado e convencional correspondem à resolução espacial de 250 m.

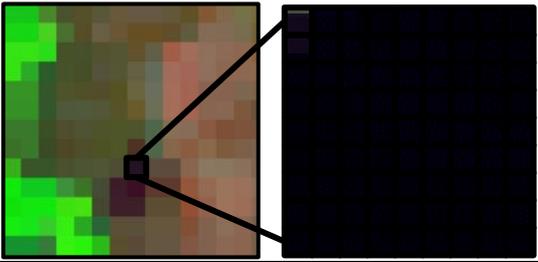
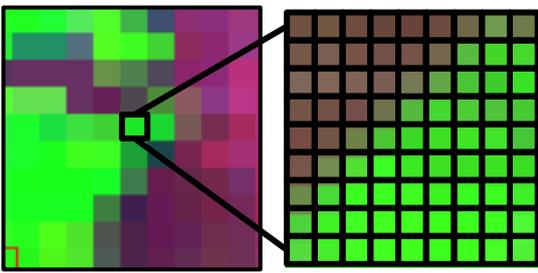
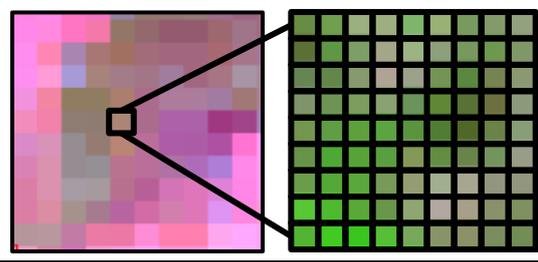


Fonte: Produção do autor.

Comparando os resultados das proporções obtidas em cada *pixel* (Tabela 5.4), observa-se que foram obtidas proporções mais condizentes quando utilizada a combinação entre os produtos de diferentes resoluções espaciais. De modo geral, as maiores diferenças observadas estiveram relacionadas à fração sombra e em áreas que apresentam grande heterogeneidade, como visto no último exemplo da Tabela 5.4. Em tais áreas heterogêneas há a tendência de minimização da probabilidade de encontrar pixels puros em imagens de

moderada e baixa resolução espacial, dificultando, assim, a seleção de endmembers.

Tabela 5.4 – Proporção dos componentes nas resoluções espaciais de 250m e 30m por pixel.

Representação do pixel em 250 m (esquerda) e 30 m (direita)	Proporção dos componentes												
	<table border="1"> <thead> <tr> <th></th> <th>MLME_{CO}</th> <th>MLME_{ES}</th> </tr> </thead> <tbody> <tr> <td>Sombra</td> <td>0,54</td> <td>0,86</td> </tr> <tr> <td>Solo</td> <td>0,38</td> <td>0,12</td> </tr> <tr> <td>Vegetação</td> <td>0,08</td> <td>0,02</td> </tr> </tbody> </table>		MLME _{CO}	MLME _{ES}	Sombra	0,54	0,86	Solo	0,38	0,12	Vegetação	0,08	0,02
	MLME _{CO}	MLME _{ES}											
Sombra	0,54	0,86											
Solo	0,38	0,12											
Vegetação	0,08	0,02											
	<table border="1"> <tbody> <tr> <td>Sombra</td> <td>0,04</td> <td>0,00</td> </tr> <tr> <td>Solo</td> <td>0,32</td> <td>0,34</td> </tr> <tr> <td>Vegetação</td> <td>0,64</td> <td>0,66</td> </tr> </tbody> </table>	Sombra	0,04	0,00	Solo	0,32	0,34	Vegetação	0,64	0,66			
Sombra	0,04	0,00											
Solo	0,32	0,34											
Vegetação	0,64	0,66											
	<table border="1"> <tbody> <tr> <td>Sombra</td> <td>0,00</td> <td>0,00</td> </tr> <tr> <td>Solo</td> <td>0,82</td> <td>0,67</td> </tr> <tr> <td>Vegetação</td> <td>0,18</td> <td>0,33</td> </tr> </tbody> </table>	Sombra	0,00	0,00	Solo	0,82	0,67	Vegetação	0,18	0,33			
Sombra	0,00	0,00											
Solo	0,82	0,67											
Vegetação	0,18	0,33											

Fonte: Produção do autor.

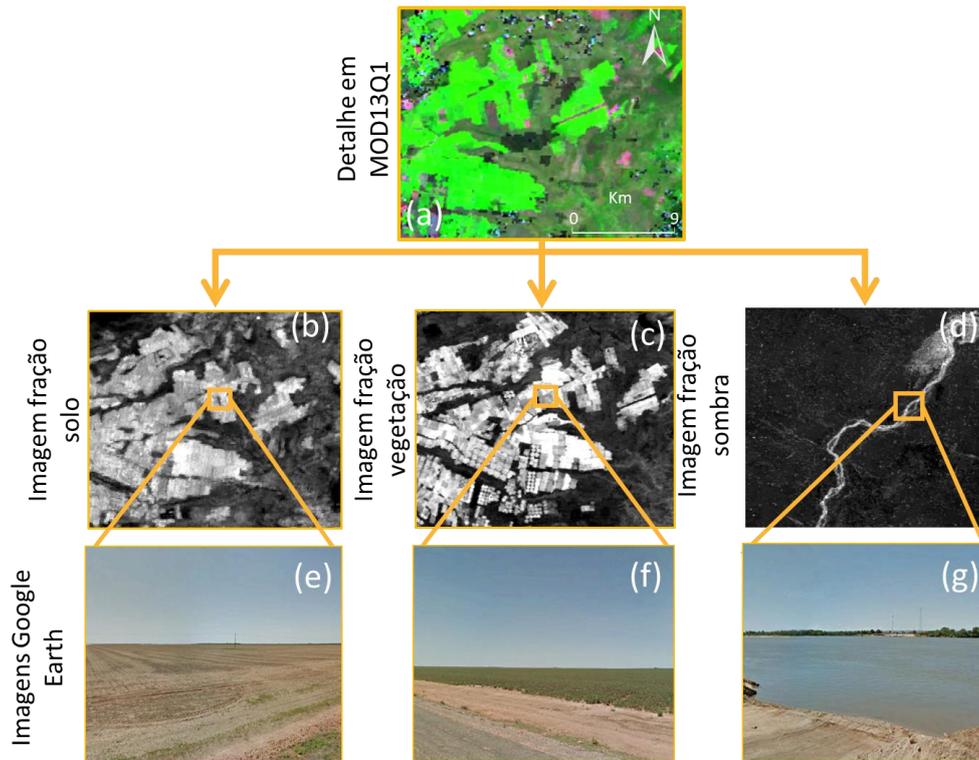
Do aspecto espacial e visual, as imagens fração podem ser usadas individualmente em composições monocromáticas ou para fazer composições coloridas (RGB) para análises posteriores. Destaca-se que o modelo linear de mistura espectral não é um classificador temático, mas proporciona a redução de dados, além de realçar as informações contidas no *pixel* para diversas aplicações (SHIMABUKURO; PONZONI, 2017).

Dessa forma, as imagens fração obtidas para os componentes solo, vegetação e sombra derivadas da última etapa são observadas na Figura 5.4. A figura representa o detalhamento dos produtos MODIS para melhor visualização dos

resultados. Observa-se que as proporções dos componentes nas imagens fração (Figuras 5.4b, 5.4c e 5.4d) são representadas pela variação da escala de cinza – brilho – nas imagens, sendo o nível de cinza escuro quando há menor proporção do componente dentro do *pixel* e o nível de cinza claro quando há maior proporção do componente dentro do *pixel*.

Para exemplificação dos resultados utilizando imagens obtidas do *Google Earth*, a figura 5.4e, 5.4f e 5.4g apresenta detalhes do solo, vegetação e corpo hídrico, demonstrando, claramente, a relação entre a presença de um determinado alvo na imagem e o seu realce nas imagens fração. Assim, a imagem fração vegetação exibe variações nos níveis de cinza que podem representar diferenças nos tipos vegetacionais encontrados no estado da Bahia, a imagem fração solo contém informações sobre solo exposto e, do mesmo modo, a imagem fração sombra destacam rios e corpos hídricos.

Figura 5.4 – Detalhe do produto MOD13Q1 utilizando falsa composição colorida em R(MIR) G(NIR) e B(Red) (a) e as respectivas imagens fração.



Onde: (a) detalhe do produto MOD13Q1 utilizando falsa composição colorida em R(MIR) G(NIR) e B(Red) e as respectivas imagens fração dos componentes (b) solo, (c) vegetação e (d) sombra, derivadas do MLME em detalhe. As figuras (e), (f) e (g) apresentam imagens obtidas do *Google Earth*, representando áreas como solo exposto, agricultura e corpo hídrico, respectivamente.

Fonte: Produção do autor (2019).

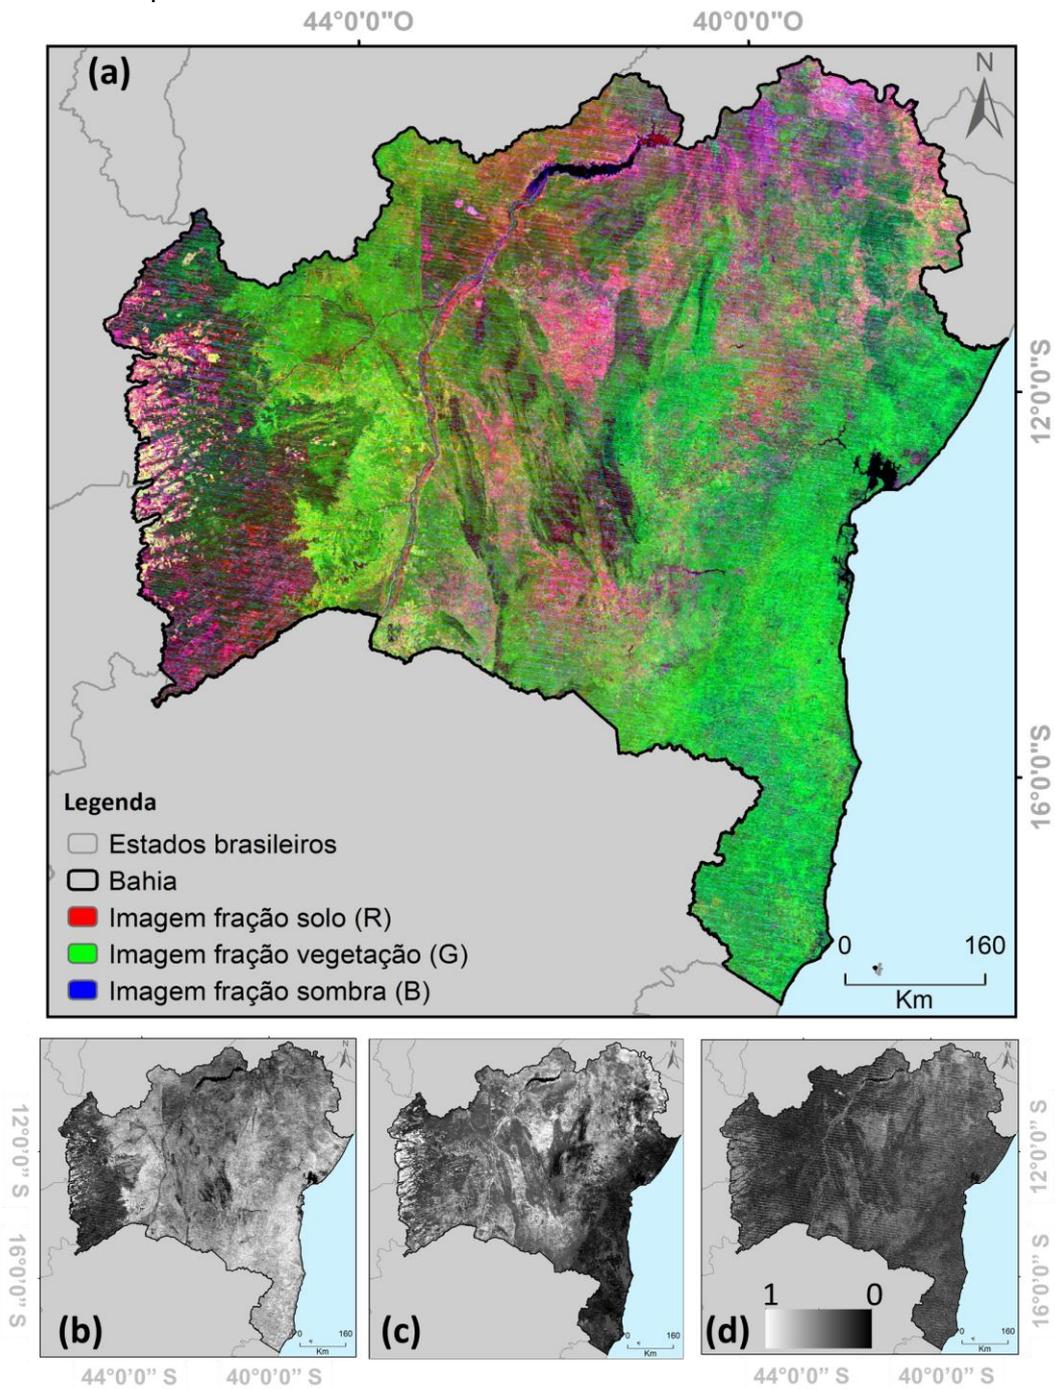
Diante dos resultados expostos sobre a etapa de estimativa dos *endmembers*, nota-se que utilizar o MLME para explorar a combinação de imagens de diferentes resoluções espaciais permitiu ao usuário o aperfeiçoamento do MLME no que se refere à determinação de *pixels* que incluam um único membro de referência, tendo em vista que o resultado do modelo depende diretamente da escolha dos parâmetros de entrada.

Assim, acredita-se que a potencialidade proposta nesta abordagem está em estender as informações contidas em escala local aplicando o MLME em imagens de baixa resolução espacial, os quais são frequentemente utilizados

em estudos regionais e globais, sem a necessidade de selecionar *pixels* puros na própria imagem de estudo, tendo em vista a menor probabilidade de encontrá-los. Esta abordagem é aplicável para outros sensores orbitais desde que seja observada a mínima diferença temporal no imageamento entre os sensores, de modo a assumir que não houveram variações de um determinado alvo entre as imagens, como descrito por Dutra et al. (2019a).

Após a etapa de definição dos *endmembers*, o MLME foi aplicado para toda a série temporal de 2000 a 2017, nas bandas do produto MOD13Q1 e posteriormente gerados os mosaicos das imagens fração contendo o valor máximo das proporções para os anos de 2000 e 2017. Como resultado desta etapa, a figura 5.5a apresenta uma composição colorida do $MLME_{max}$ para o ano 2000, onde as cores vermelho (R), verde (G) e azul (B) foram definidas para as máximas proporções das imagens fração solo, vegetação e sombra. As Figuras 5.5b, 5.5c e 5.5d representam individualmente as imagens fração em escala de cinza. Do mesmo modo as Figuras 5.6a, 5.6b, 5.6c e 5.6d apresentam o $MLME_{max}$ gerado para 2017.

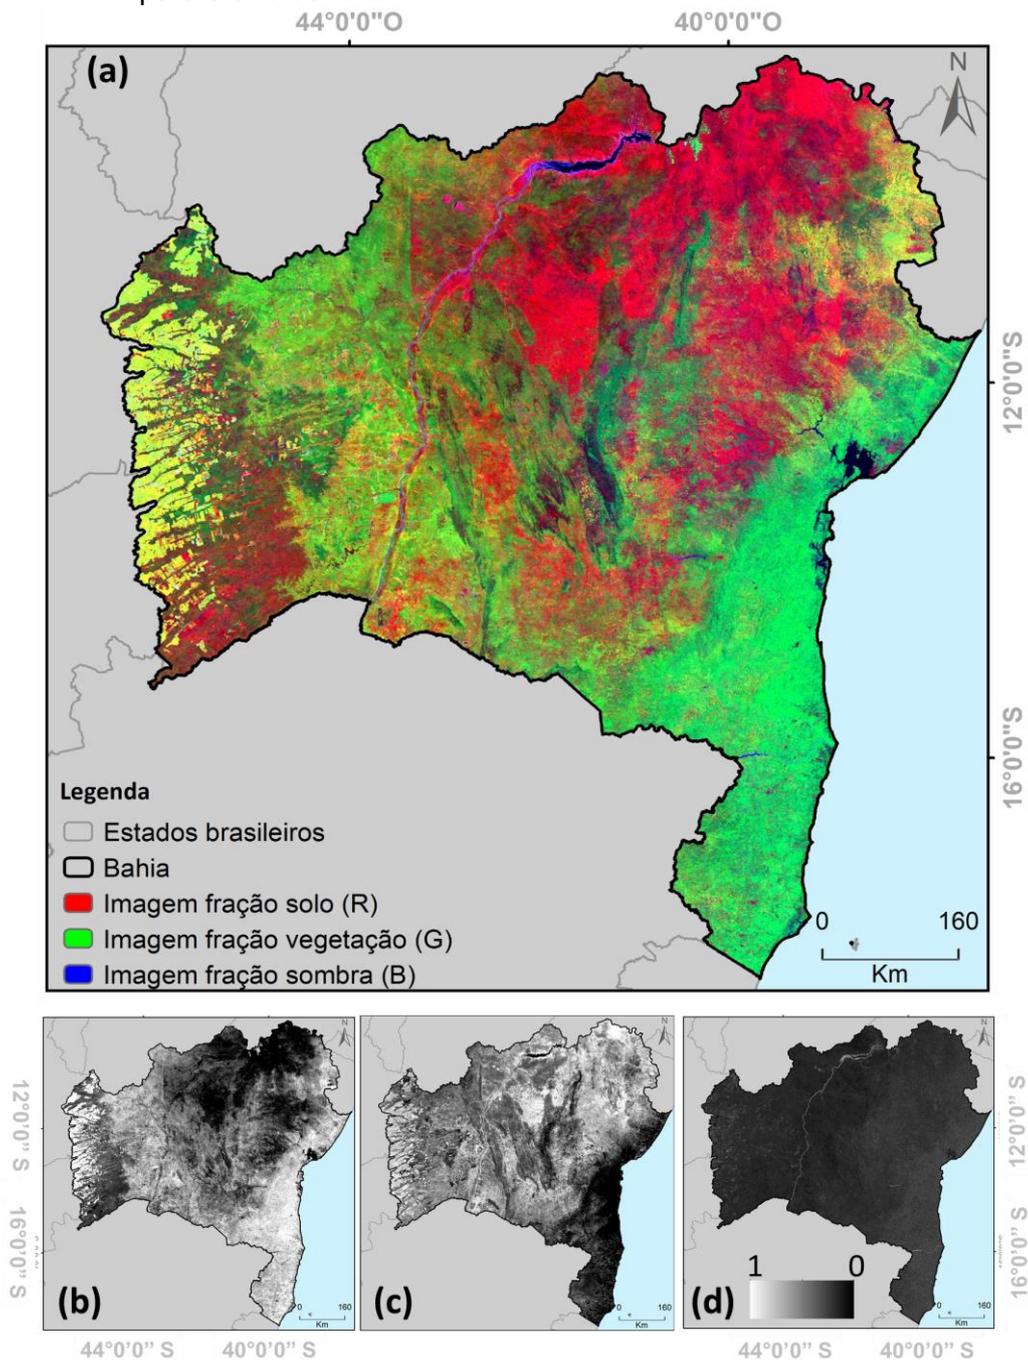
Figura 5.5 – Mosaico das imagens fração contendo o valor máximo das proporções para o ano 2000.



Onde: (a) composição RGB utilizando as imagens fração de máxima proporção do solo, vegetação e sombra, respectivamente, derivadas do $MLME_{est}$ e aplicadas para o estado da Bahia utilizando resolução espacial de 250 m em 2000. As Figuras (b), (c) e (d) representam as imagens fração solo, vegetação e sombra, respectivamente.

Fonte: Produção do autor.

Figura 5.6 – Mosaico das imagens fração contendo o valor máximo das proporções para o ano 2017.



Onde: (a) composição RGB utilizando as imagens fração de máxima proporção do solo, vegetação e sombra, respectivamente, derivadas do $MLME_{est}$ e aplicadas para o estado da Bahia utilizando resolução espacial de 250 m em 2017. As figuras (b), (c) e (d) representam as imagens fração solo, vegetação e sombra, respectivamente.

Fonte: Produção do autor.

Observando individualmente as composições coloridas, nota-se que as imagens fração de máxima proporção ilustram a distribuição espacial da vegetação nativa, agricultura, solo e corpos hídricos com as suas distribuições reais. Como exemplo, em verde são realçadas as áreas de vegetação, como as áreas florestadas da Mata Atlântica no Leste do estado e também as áreas agrícolas concentradas especialmente no Oeste. Do mesmo modo, em vermelho são realçadas as áreas com solo exposto ou áreas cuja vegetação apresenta baixa resposta espectral, como, por exemplo as áreas em estágio de desertificação ou de pastagem degradada.

Destaca-se que a variação nos tons da composição colorida está associada aos diferentes tipos de vegetação que apresentam variações devido aos fatores edafoclimáticos presentes no estado da Bahia, assim como também pode estar associado aos diferentes regimes de manejo das produções agrícolas. Tais informações em conjunto podem, por exemplo, agregar o uso de classificadores temáticos de uso e cobertura da terra em análises posteriores.

Variações entre os anos também são observadas especialmente nas áreas agrícolas no Oeste e em áreas que apresentaram maior proporção de solo. Nos últimos anos a Bahia tem sido considerada como um dos principais estados produtores no país, apresentando uma agropecuária em extensão e tecnológica. Neste sentido, considerando a utilização de um único *endmember* para toda a série temporal, sugere-se que a variação no brilho das imagens fração vegetação (Figuras 5.5b e 5.6b) e conseqüentemente variação da proporção da vegetação nas áreas do oeste do estado, estejam relacionadas às variações no sistema de plantio adotados entre os 18 anos de estudo. Estudos relatam que alterações na densidade de plantio podem diminuir a produção individual das plantas (FERREIRA et al., 2015), assim como também o tamanho populacional de plantas altera proporcionalmente o índice de área foliar (HEIFFIG et al., 2006). Considerando que nos últimos anos houve uma tendência de adensamento de plantios, ou seja, aumento da concentração de plantas por área, espera-se que tais fatores tenham proporcionado o aumento

na produtividade das culturas agrícolas presentes no estado, resultando nesta variação entre as proporções do $MLME_{max}$.

Outro fator que pode estar influenciando nesta variação é a falta de dados do produto MODIS em janeiro de 2000, que corresponde ao período anterior de lançamento dos primeiros dados disponíveis do sensor, e, assim, ser impactado pelo calendário agrícola na região, principalmente pelo período de pico vegetativo de alguns cultivares (AIBA, 2018).

Outra variação observada entre os anos na composição do $MLME_{max}$ é a expansão das áreas com maior proporção da fração solo. Esta expansão é visualizada especialmente nos limites do bioma Caatinga, que nas últimas décadas tem sido impactado por extremos climáticos (INCT, 2016), dentre eles, a ocorrência de desastres naturais como a seca.

Devido à sua intensidade e recorrência, a seca torna-se o desastre mais importante e impactante que afeta a população brasileira, sendo responsável por mais de 50% dos desastres naturais registrados no Brasil entre 1991 e 2012 (BRITO et al., 2018). Este é um fato preocupante pois alguns modelos climáticos desenvolvidos pelo *Intergovernmental Panel on Climate Change* (IPCC) indicam tendências negativas na chuva dos trópicos (MARENGO et al., 2009).

No Nordeste, a alta variabilidade e irregularidade da distribuição espaço-temporal da precipitação (CUNHA et al., 2015) são características intrínsecas da região. Assim, longos períodos de escassez de chuvas são frequentes (JACQUES et al., 2014) e eventos extremos de seca, como a mais intensa em décadas que atingiu a região entre 2012 e 2017 (BRITO et al., 2017; MARENGO et al., 2016), são prováveis que continuem seguindo com uma tendência de aumento em frequência e intensidade. Tais particularidades tornam o Nordeste um dos ecossistemas mais vulneráveis ao aumento do déficit hídrico no mundo (MARENGO et al., 2016; IPCC, 2014).

De modo geral, as secas implicam em perdas substanciais na produção de culturas (RODRÍGUEZ-PUEBLA et al., 2007), aumento do risco de incêndios florestais (PAUSAS, 2007) e declínio na disponibilidade hídrica para a

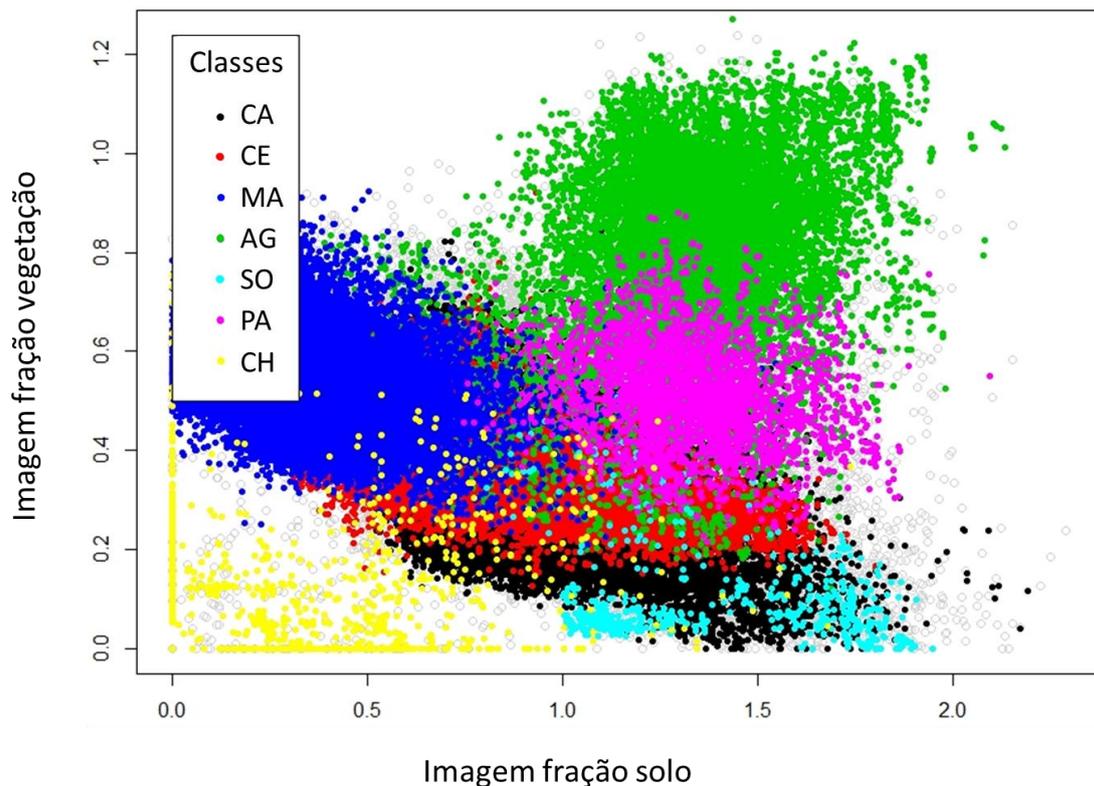
vegetação (LIMOUSIN et al., 2009). Além disso, são observadas tendências significativas a processos de desertificação em regiões áridas e semiáridas em períodos de seca (NICHOLSON et al., 1988).

Diante deste exposto, tais evidências podem justificar a expansão das proporções da fração solo em grande parte do estado e redução na proporção da fração vegetação em 2017.

5.2 Classificação do uso e cobertura da terra

A partir da metodologia apresentada na seção 4.8, foi analisada a dispersão de pontos amostrais a partir de um gráfico de importância que fornece informações sobre a influência de cada variável de entrada, neste caso, apenas para as imagens fração solo e vegetação (Figura 5.7). Tais informação indicam o padrão temporal das classes em relação à variação das proporções de solo e vegetação ao longo do ano. Esta etapa foi obtida anteriormente a etapa de classificação pelo RF, sendo utilizado pelo classificador como parâmetro de treinamento das amostras.

Figura 5.7 – Gráfico de dispersão dos pontos evidencia a associação entre as classes utilizadas e as proporções do $MLME_{max}$.



Onde: Classes foram representadas em Caatinga (CA), Cerrado (CE), Mata Atlântica (MA), Agricultura (AG), Solo (SO), Pastagem (PA) e Corpos Hídricos (CH).

Fonte: Produção do autor (2019).

O gráfico de dispersão dos pontos evidencia a associação entre as classes utilizadas e as proporções do $MLME_{max}$, sendo esperado que quanto maior a distinção destas relações, melhor será a separabilidade das classes pelo classificador. Observa-se que existe melhor separação entre as classes de MA e AG. A vegetação de MA apresenta altas proporções da fração vegetação e as menores proporções da fração solo, evidenciando que as espécies de Mata Atlântica apresentam efeitos mais sutis da sazonalidade climática e, conseqüentemente, mudanças foliares são menos perceptíveis durante o ano uma vez que estão presentes em ambientes com maior suprimento de água no solo (BORCHERT, 1999).

Dentre todas as classes utilizadas, a classe AG é a que apresenta as maiores proporções da fração solo e, ao mesmo tempo, as maiores proporções da fração vegetação. Este resultado é justificado pelo uso do $MLME_{max}$ na série temporal de um ano, ou seja, em um determinado período do ano as áreas agrícolas apresentam elevada resposta espectral do solo durante o preparo do mesmo ou após a colheita, entretanto, ressalta-se que em espécies agrícolas perenes esta relação não é tão acentuada. Do mesmo modo, também apresentam elevada resposta espectral da vegetação no ano, especialmente quando os cultivares atingem o seu máximo vigor vegetativo. Assim, a diferenciação espectro-temporal das espécies cultivadas devido aos padrões fenológicos durante as fases de desenvolvimento são facilmente identificadas quando utilizadas séries temporais de imagens orbitais (SILVA JUNIOR; RODRIGUES, 2014). Na Bahia, devido à variabilidade pluviométrica, o calendário agrícola pode variar entre as espécies anuais cultivadas no estado, evidenciando, ainda mais, a necessidade de utilização de séries temporais.

Nas áreas de pastagem, observa-se valores mais elevados de proporção da fração solo quando comparado a proporção da fração vegetação, que, por sua vez, atinge valores intermediários. Na Bahia existe a variação entre pastagens manejadas, localizadas especialmente no oeste do estado e que apresentam resposta espectral semelhante à agricultura anual, e pastagens degradadas em maior abrangência. De acordo com Costa et al. (2000), em áreas bem manejadas as pastagens apresentam bons índices de produtividade, entretanto, a retirada da vegetação nativa original, bem como a pressão de uso do solo, faz com que os níveis produtivos das pastagens caiam em virtude da substituição de gramíneas menos produtivas.

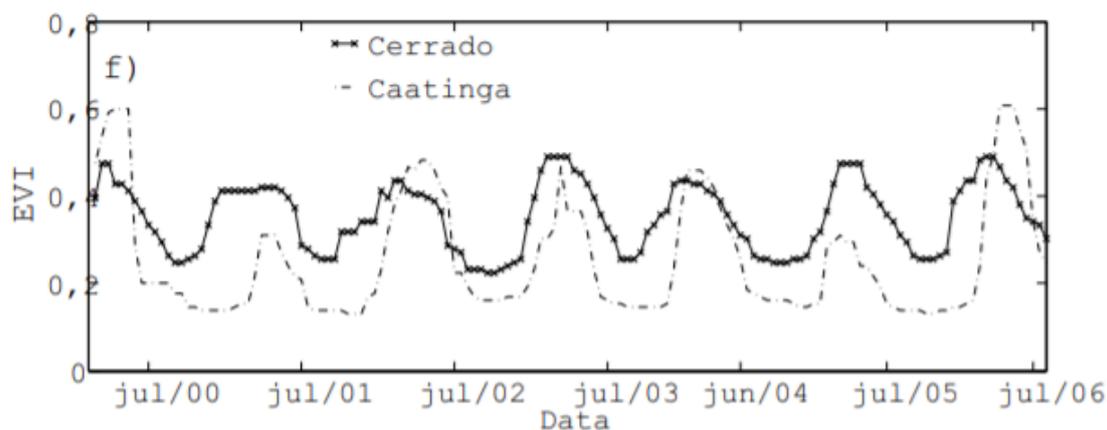
Além disso, grandes áreas do bioma Caatinga tem sido utilizadas como pastagem extensiva, ocasionando altos níveis de degradação. Alves et al. (2009) apontam a utilização de espécies nativas da Caatinga pelos pequenos agropecuaristas para a alimentação dos animais durante os períodos de estiagem em regiões da Bahia. Assim, quando o efetivo do rebanho é muito grande e criado solto, há a sobrecarga das pastagens e diversos efeitos

múltiplos, dentre eles, fenômenos de erosão do solo e comprometimento da capacidade hídrica do mesmo.

Dessa forma, aliados a outros fatores socio-econômicos-ambientais, o super pastoreio provoca uma tendência de redução de biomassa vegetal. Isso é resultado de que, após anos seguidos de sobrecarga, há o aumento da exposição dos solos, corroborando com a maior proporção desta fração em grandes áreas de pastagem na Bahia e menor proporção da vegetação ao longo do ano.

Considerando a vegetação nativa da Caatinga e Cerrado, observa-se que ambas apresentaram a maior semelhança na dispersão dos pontos em relação às outras classes. A maior diferença observada está no decréscimo na proporção da fração vegetação na classe CA devido à menor reflectância espectral das espécies de Caatinga em relação às espécies de Cerrado. Além disso, proporções de solo são ligeiramente mais elevadas neste primeiro bioma, apresentando padrões mais próximos à classe solo exposto. Isso se deve ao fato de que a vegetação da Caatinga é constituída principalmente por árvores baixas e arbustos, cujo estrato herbáceo é formado por plantas anuais (FERNANDES; QUEIROZ, 2018) e apresenta forte influência do solo nas áreas vegetadas, enquanto as espécies lenhosas do Cerrado apresentam porte mais elevado atingindo, em alguns locais, altura média superior aos 10 m (IBGE, 2012). Este fato também é evidenciado quando analisado temporalmente o comportamento espectral da vegetação do Nordeste. Neste sentido, Formigoni et al. (2011) apontam que a vegetação de Caatinga apresentou a maior variação intranual (mensal e sazonal) do EVI, obtendo coeficiente de variação de 53%, enquanto o bioma Cerrado apresentou 22% (Figura 5.8).

Figura 5.8 – Comportamento temporal do EVI nos biomas Caatinga e Cerrado.



Fonte: Adaptado de Formigoni et al. (2011).

Com as amostras utilizadas para treinamento do classificador RF, é possível gerar uma matriz de confusão informando as taxas de acerto de cada classe em relação às amostras inseridas (Tabela 5.5). Esta matriz é calculada com base no número de pixels utilizados para treinamento, que pode variar de acordo com o tamanho dos polígonos utilizados para amostragem.

Tabela 5.5 – Matriz de confusão entre aproximadamente 50.000 pixels utilizados para treinamento do classificador RF.

	CA	CE	MA	AG	PA	SO	CH	Taxa de erro (%)
CA	43493	2422	4957	477	65	174	10	15,10
CE	1483	46108	2184	229	8	421	1	8,57
MA	3899	2002	43409	70	2	615	7	13,18
AG	104	1306	28	48409	0	1	0	2,87
PA	23	3	1	0	48611	1	0	0,57
SO	6	3	3	1	1	50016	0	0,25
CH	7	5	4	0	0	0	49999	0,31
							Média	5,85%

Onde em cinza (diagonal) são apresentados o número de *pixels* classificados corretamente e em vermelho a classe com o maior número de *pixels* classificados incorretamente.

Fonte: Produção do autor.

A partir da metodologia apresentada na seção 4.9, foram obtidas as acurácias global, do produtor e usuário, ao intervalo de 95% de confiança, para o ano 2000 (Tabela 5.6) e para o ano 2017 (Tabela 5.7).

Tabela 5.6 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra referente ao ano 2000.

Classificação ano 2000	Classe	Referência						
		CA	CE	MA	AG	PA	SO	CH
	CA	0,29	0,04	0,01	0,01	0,01	0,01	0,00
CE	0,02	0,11	0,01	0,01	0,01	0,00	0,00	
MA	0,01	0,02	0,20	0,01	0,01	0,00	0,00	
AG	0,00	0,01	0,01	0,08	0,01	0,01	0,00	
PA	0,00	0,00	0,00	0,00	0,01	0,00	0,00	
SO	0,01	0,00	0,00	0,00	0,01	0,07	0,00	
CH	0,00	0,00	0,00	0,00	0,00	0,00	0,01	
Wi*	0,33	0,18	0,23	0,11	0,05	0,09	0,01	
Usuário	0,81	0,73	0,79	0,64	0,71	0,76	0,95	
Produtor	0,88	0,60	0,88	0,69	0,64	0,77	0,69	
Acurácia Global	0,77							

* *Wi a proporção de cada classe.*

Fonte: Produção do autor.

Tabela 5.7 – Acurácias globais, do produtor e usuário ponderadas pela área, por classe de uso e cobertura da terra referente ao ano 2017.

Classificação ano 2017	Classe	Referência						
		CA	CE	MA	AG	PA	SO	CH
	CA	0,21	0,04	0,01	0,00	0,03	0,01	0,00
CE	0,03	0,15	0,01	0,01	0,01	0,00	0,00	
MA	0,01	0,02	0,09	0,01	0,00	0,00	0,00	
AG	0,00	0,01	0,01	0,05	0,01	0,00	0,00	
PA	0,01	0,01	0,00	0,02	0,13	0,03	0,00	
SO	0,01	0,00	0,00	0,00	0,01	0,04	0,00	
CH	0,00	0,00	0,00	0,00	0,00	0,00	0,01	
Wj*	0,31	0,21	0,13	0,08	0,06	0,20	0,01	
Usuário	0,70	0,69	0,66	0,58	0,63	0,69	0,90	
Produtor	0,77	0,67	0,75	0,48	0,67	0,43	0,79	
Acurácia Global	0,67							

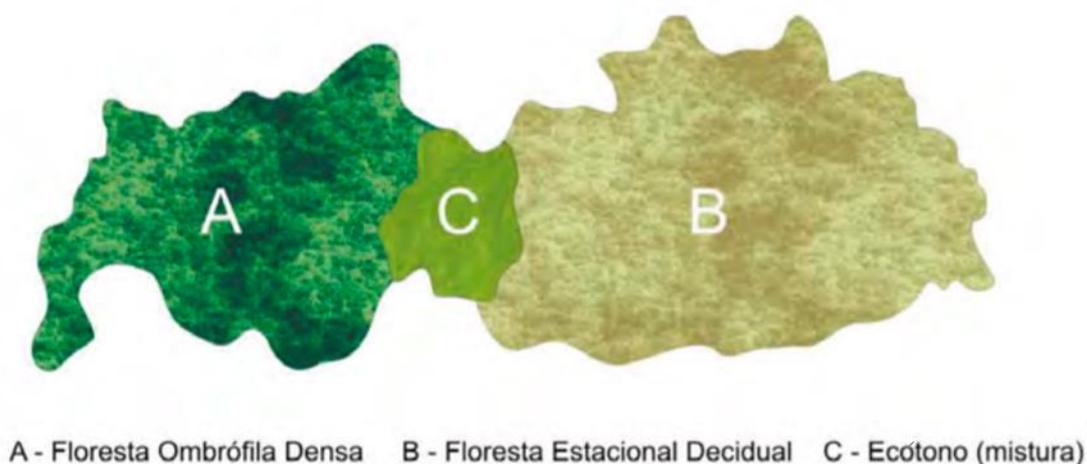
* *Wj* a proporção de cada classe.

Fonte: Produção do autor.

Do exposto acima, infere-se que a maior confusão entre as classes está relacionada às vegetações de domínio da Caatinga, Cerrado e Mata Atlântica. Tais confusões podem ocorrer devido à semelhança entre as classes de CA e CE, como visto na Figura 5.8, bem como em áreas de ecótono, ou seja, áreas em que há o contato entre tipos de vegetação com estruturas semelhantes (Figura 5.9). Tais áreas são dificilmente mapeadas até mesmo por interpretação visual, mesmo quando os tipos de vegetação apresentam estruturas fisionômicas diferentes como, por exemplo, no Raso da Catarina

localizado na Bahia, área inserida no contato entre Savana (Cerrado), Savana-Estépica (Caatinga) e Floresta Estacional (Mata Atlântica) na forma de ecótono. Isto ocorre porque os elementos que se misturam são indivíduos isolados e dispersos, formando conjuntos geralmente muito homogêneos (IBGE, 2012).

Figura 5.9 – Esquema de área considerada ecótono.



Fonte: Adaptado de IBGE (2014).

Além disso, Borges e Sano (2014) evidenciam que o Cerrado Típico (Savana Arborizada) é a fitofisionomia com maior representação de Cerrado ainda existente no oeste da Bahia, entretanto, a mais suprimida. Tal formação é caracterizada por vegetação rala, de porte arbóreo arbustivo, atingindo alturas entre 3 e 6 m (GIROLAMO NETO, 2018), assemelhando-se com a fitofisionomia de Savana Estépica (Caatinga) Florestada (IBGE, 2012).

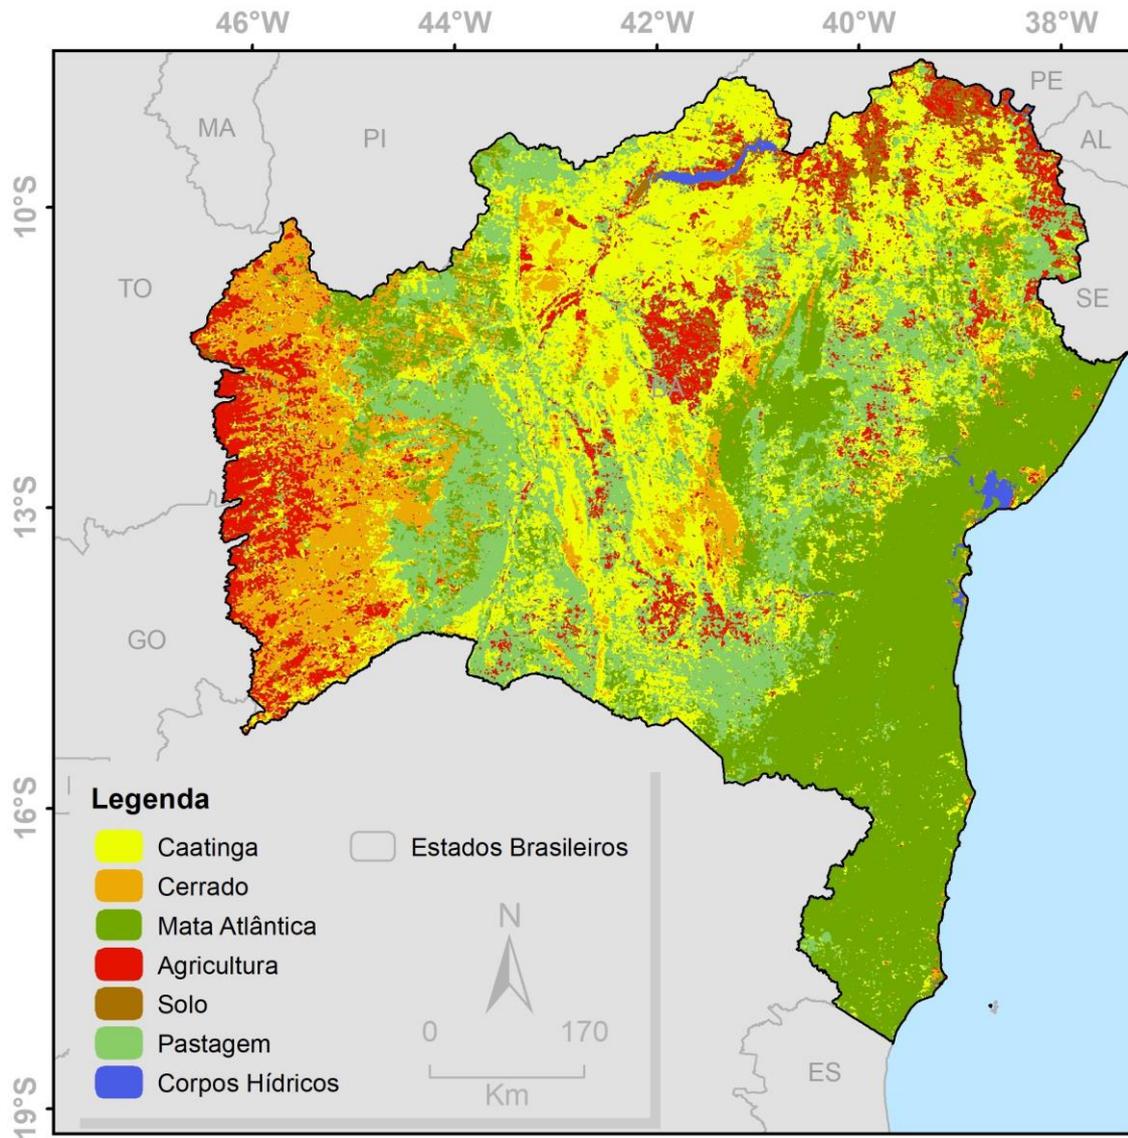
Analisando a matriz de confusão geradas entre as amostras de treinamento da classe AG, nota-se que a maior confusão está relacionada à classe CE, o que pode estar relacionado à principal fronteira agrícola no estado da Bahia inserida no bioma. Além disso, Coutinho et al. (2012) apontam à dificuldade no mapeamento de áreas agrícolas com o produto MODIS, visto que a resolução espacial do MODIS contamina a resposta espectral causada pelos diferentes

usos e coberturas de áreas adjacentes à pequenas áreas agrícolas, descaracterizando o comportamento típico da agricultura anual.

As classes PA e SO apresentaram os principais erros associados à classe CA, cujo bioma apresenta as maiores áreas em processos de desertificação e grandes áreas de pastagem degradado quando comparado aos outros biomas presentes no estado, como discutido anteriormente.

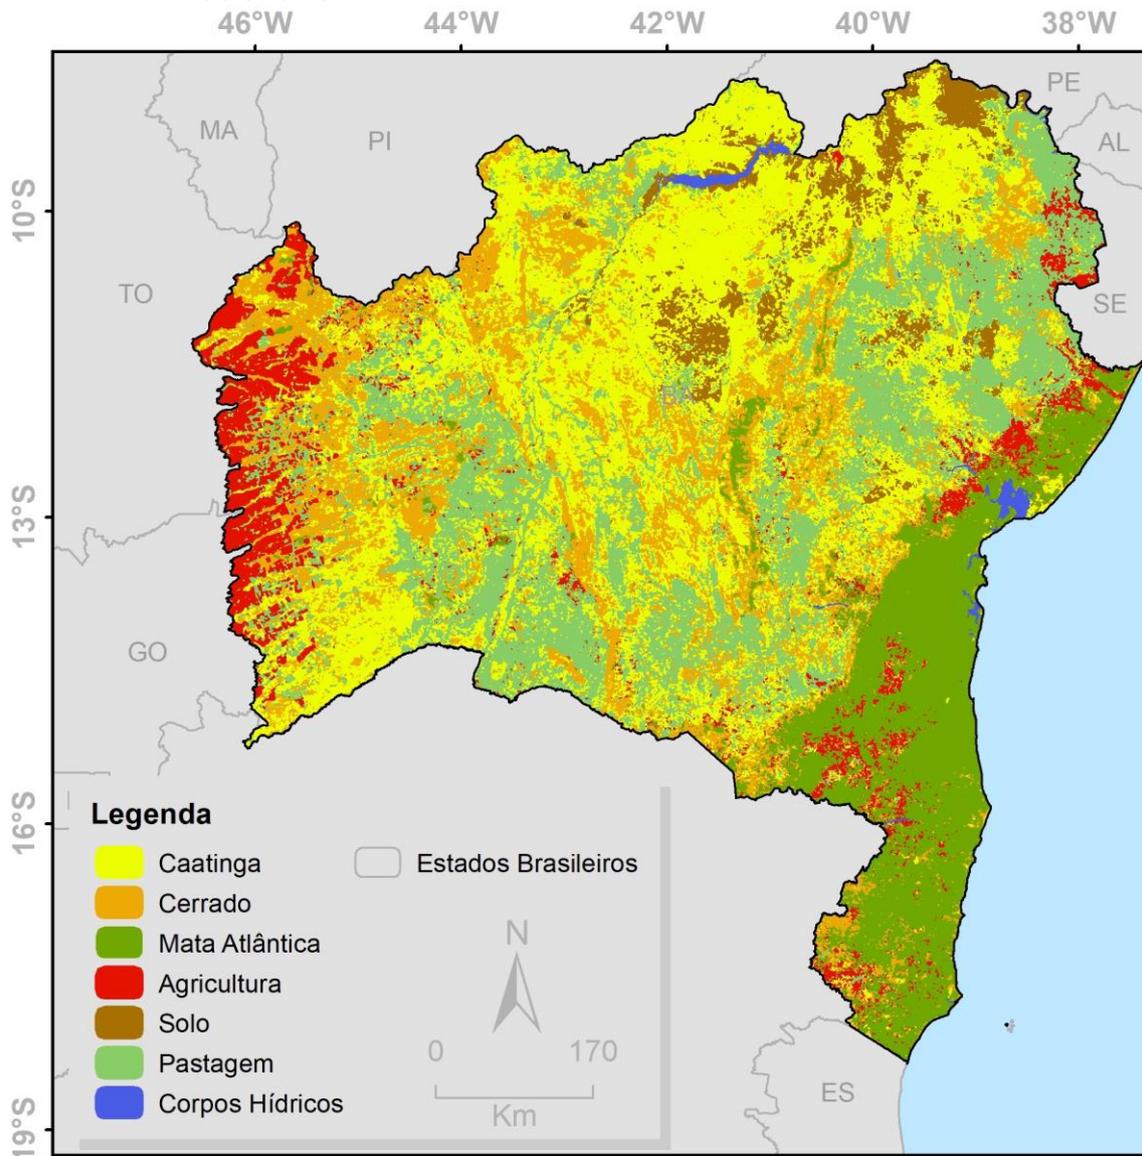
O resultado final dos mapas de uso e cobertura da terra obtidos para os anos 2000 e 2017 pela abordagem proposta neste trabalho exhibe a espacialização das classes temáticas da área de estudo (Figuras 5.10 e 5.11).

Figura 5.10 – Mapa base de uso e cobertura da terra para o estado da Bahia referente ao ano 2000.



Fonte: Produção do autor (2019).

Figura 5.11 – Mapa base de uso e cobertura da terra para o estado da Bahia referente ao ano 2017.



Fonte: Produção do autor (2019).

A Tabela 5.8 exhibe a quantificação das classes mapeadas por km² em cada ano classificado. Como era esperado, as classes CA e MA, apresentaram redução das suas áreas entre os 18 anos analisados, tendo a classe CA a redução em 13,56% da sua área mapeada em 2000 e a classe MA a redução foi de 47,71%, sendo a classe mais afetada.

Tabela 5.8 – Quantificação das classes mapeadas em 2000 e 2017.

Classe	2000 (km²)	2017 (km²)	Variação (%)
CA	206.614,00	178.590,69	13,56
CE	87.690,37	117.304,79	25,24
MA	150.443,50	78.666,19	47,71
AG	68.911,56	57.991,07	15,84
SO	9.281,43	32.647,00	71,57
PA	55.204,063	113.191,81	51,23
CH	4.718,938	4.529,75	4,01

Fonte: Produção do autor.

Na classe CH também foram observadas mudanças relacionadas à sua redução em 2017, que atingiu 4,01% de área reduzida. Tal redução pode estar associada à bacia do rio São Francisco, presente no estado da Bahia, que vem enfrentando condições hidrológicas adversas nos últimos anos com chuvas e vazões abaixo da média, tendo o seu pior ano hidrológico entre 2016/2017. Tal fato foi responsável pela redução da sua vazão para 600 m³/s no reservatório do Sobradinho, sendo considerada a menor vazão da história autorizada pela ANA e o IBAMA no estado da Bahia (2017).

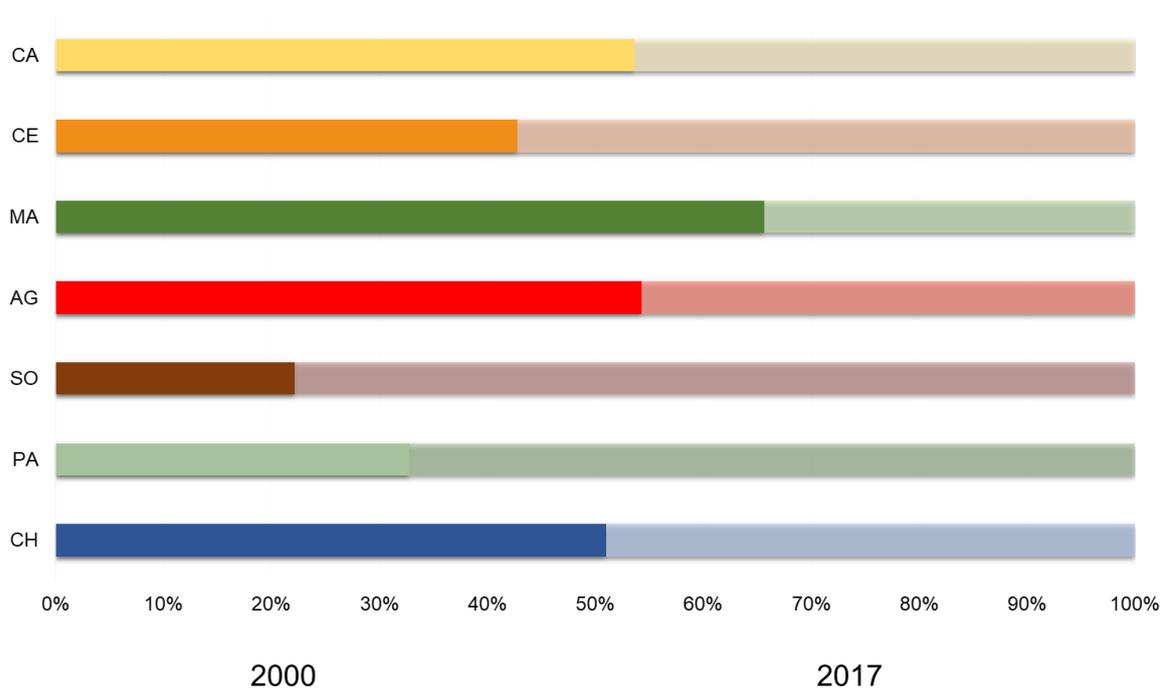
Do mesmo modo, o aumento nas áreas de SO e PA são observadas entre os dois períodos. De todas as classes analisadas, a que mais sofreu alteração e, neste caso, expansão, foi a classe SO, cujo aumento foi de 71,57% em comparação à classificação anterior. Este resultado é corroborado com os trabalhos realizados por Tomassela et al. (2018), Dourado (2017) e Vieira et al. (2015) na classificação de áreas degradadas e em risco de desertificação, assim como áreas em condições de estresse hídrico (CUNHA et al., 2015) no Nordeste, sendo observado grandes áreas afetadas particularmente na Bahia.

A classe PA obteve expansão de 51,23%, sendo observado o seu aumento especialmente no bioma Caatinga devido aos aspectos já discutidos anteriormente. Assim, esta classe ocupa aproximadamente 20% de toda o

território do estado, atrás apenas dos biomas Caatinga e Cerrado em porcentagem de área.

As classes CE e AG, entretanto, apresentaram resultados inversamente ao esperado. Onde, na classe CE houve o aumento de 25,24% e na classe AG houve o decréscimo de 13,56 % da sua área total mapeada em 2000 (Figura 5.11).

Figura 5.11 – Quantificação das classes mapeadas em 2000 e 2017.



Fonte: Produção do autor.

Também é observado que grandes áreas mapeadas como a classe MA em 2000 foram mapeadas como CE em 2017. Este fato pode estar relacionado às áreas desmatadas do bioma Mata Atlântica e, conseqüentemente, aumento de pequenos fragmentos florestais. Assim, devido ao tamanho do pixel MODIS, maior proporção da fração solo será observada nessas áreas, e, possivelmente maior semelhança na proporção das imagens fração com áreas de Cerrado.

Em relação às áreas de agricultura, muitas áreas foram classificadas como PA e SO em 2017. Como discutido anteriormente sobre a dispersão dos pontos de cada classe, a classe PA exibiu um nível de proporção da fração vegetação inferior a classe AG e, em contrapartida, a classe SO se diferenciava pela menor proporção da fração vegetação quando comparada às demais classes, com exceção da classe CH.

Uma explicação para as inconsistências na classificação pode estar relacionada aos eventos extremos de seca, como a 2012 e 2017 (BRITO et al., 2017; MARENGO et al., 2016). De acordo com Cunha et al. (2015), a seca é um fenômeno ecológico que se manifesta na redução da produção agrícola. Em terras áridas e semi-áridas a precipitação é sazonal, o que afeta a vegetação diretamente na mesma estação e indiretamente na próxima temporada através do “efeito memória” (PHILIPPON et al., 2005) e “efeito de recuperação”, ou seja, a dificuldade da vegetação para se recuperar de condições de seca (MARTINY et al., 2005). O efeito memória é definido como a capacidade de os ecossistemas semiáridos se beneficiarem dos excedentes hídricos, o que indica que existe claramente uma memória da precipitação passada em um intervalo de tempo de um ano (SCHWINNING; SALA, 2004; MARTINY et al., 2005).

Para Cunha et al. (2015), a seca pode reduzir a resiliência, tornando as plantas mais vulneráveis a perturbações recorrentes. Assim, a vegetação pode ser duramente afetada por uma seca se ela for precedida por outro ano seco – efeito de recuperação –. Inversamente, a vegetação também poderá se desenvolver mesmo com baixos níveis de precipitação caso o ano anterior tenha sido chuvoso – efeito de memória –.

Em resumo, considerando que 2017 também foi precedido por anos secos, as áreas agrícolas podem ter sido mais impactadas, sugerindo uma possível redução da atividade fotossintética da vegetação e, conseqüentemente, maior confusão entre os tipos de cobertura da terra, principalmente no bioma Caatinga.

A substituição das classes mapeadas de AG para SO também pode estar associada à degradação do solo pela agricultura. De acordo com Sampaio et al. (2005) a degradação no Nordeste quase sempre se inicia com o desmatamento e a substituição da vegetação nativa por outra cultivada. Com isso, o descobrimento do solo favorece o processo de erosão e o cultivo continuado sem reposição dos nutrientes retirados leva à perda da fertilidade. Não menos impactado, nas áreas de cultivo irrigado o uso de água com teores elevados de sais, o mau manejo dos ciclos de molhamento e a ausência de drenagem podem levar à salinização. Como também o uso de equipamentos pesados em solos de textura pesada e com teores de água inadequados podem acarretar a compactação dos solos.

Outra explicação está na escolha do *endmember* para a geração das imagens fração vegetação que foram obtidos de alvos agrícolas, como as observadas no oeste da Bahia e cujos cultivares adotam a agricultura de precisão. Assim, associada à resolução espacial, aos fatores climáticos e parâmetros de entrada do MLME, áreas agrícolas podem ter sido subestimadas em 2017. Além disso, as pastagens apresentam elevada dinâmica anual e alta sensibilidade a sazonalidade climática, o que contribui para a confusão existente com outras culturas agrícolas no processo de classificação (SANCHES, 2004; MELO, 2017).

Além disso, a abordagem apresentada é baseada *pixel* a *pixel*, que apresenta problema de representatividade espacial, ou seja, muitos *pixels* individuais são classificados como uma classe específica. Para isto, alguns métodos de análise de imagens são baseados em objetos geográficos (Geographic Object-Based Image Analysis – GEOBIA), que considera a partição da imagem em regiões homogêneas formadas por *pixel*, denominadas de segmentos ou objetos (KÖRTING, 2012; COSTA, 2017). Esse método torna-se, assim, uma alternativa frequente para a classificação convencional de imagens por *pixel* em mapeamentos da cobertura da terra (BLASCHKE, 2010). Entretanto, como verificado por Dutra et al. (2019b) e Dutra et al. (2019c), em algumas áreas de Caatinga e Cerrado, o uso de segmentadores torna o processamento mais complexo, dadas as características de distribuição das espécies.

Diante de resultados expostos com este método proposto de mapeamento, observa-se que a classificação da vegetação lenhosa no espaço e no tempo utilizando dados de Sensoriamento Remoto se torna um desafio em regiões cuja vegetação apresenta distribuição dispersa, além da baixa cobertura e baixa densidade de árvores e arbustos. Além disso, muitos métodos não fazem a separação dos efeitos das espécies lenhosas e herbáceas, contribuindo para o aumento da área foliar e biomassa nas quantificações (BRANDT et al., 2016; KO et al., 2009).

O uso de modelos de mistura espectral para estimar a cobertura de plantas lenhosas em regiões semiáridas utilizando a fração vegetação (*photosynthetic vegetation* – PV) durante a estação seca foi reportado em estudos recentes adicionando a fração NPV (*non-photosynthetic vegetation*) (THORP et al., 2013; YANG et al., 2012) (Figura 1), que pode incluir materiais como: matéria orgânica seca, serapilheira, madeira e troncos secos.

De acordo com Yang et al. (2012), utilizar apenas a fração vegetação pode superestimar a vegetação arbórea em regiões semiáridas e dessa forma, o uso do NPV pode ser útil para analisar a dinâmica, função e estrutura da vegetação. Assim como, o uso das frações de sombra pode ser útil para distinguir árvores e arbustos de gramíneas de mais baixa estatura.

Existem estudos que utilizam os quatro componentes: PV, NPV, sombra e solo para gerar classificações da cobertura da terra principalmente em áreas florestais com elevada biomassa, como a floresta Amazônica. Entretanto, poucos estudos investigaram a aplicabilidade desses componentes para quantificar e monitorar as mudanças da cobertura arbórea em regiões áridas e semiáridas e com baixa biomassa (YANG et al., 2012).

Em relação ao classificador utilizado, o RF apresentou eficiência em conjuntos de dados de alta dimensão e testes com diferentes variáveis como entrada no modelo, como apresentados por outros autores (BREIMAN, 2001; PAL; MATHER, 2003). Além disso, alguns trabalhos apontam a classificação mais confiável das categorias mais heterogêneas, que são as mais difíceis de

classificar como, por exemplo, vegetações arbustivas (FRANKLIN et al., 2000, ROGAN et al., 2008).

5.3 Perfis temporais das imagens fração

Com base no uso de dados multitemporais das imagens fração vegetação, solo e sombra, foram gerados os perfis temporais exibidos nas Figuras 5.12, 5.13, 5.14 e 5.15. Esta metodologia foi proposta de modo a observar as potencialidades das imagens fração para o monitoramento da cobertura da terra, sendo, portanto, uma análise qualitativa dos perfis temporais obtidos.

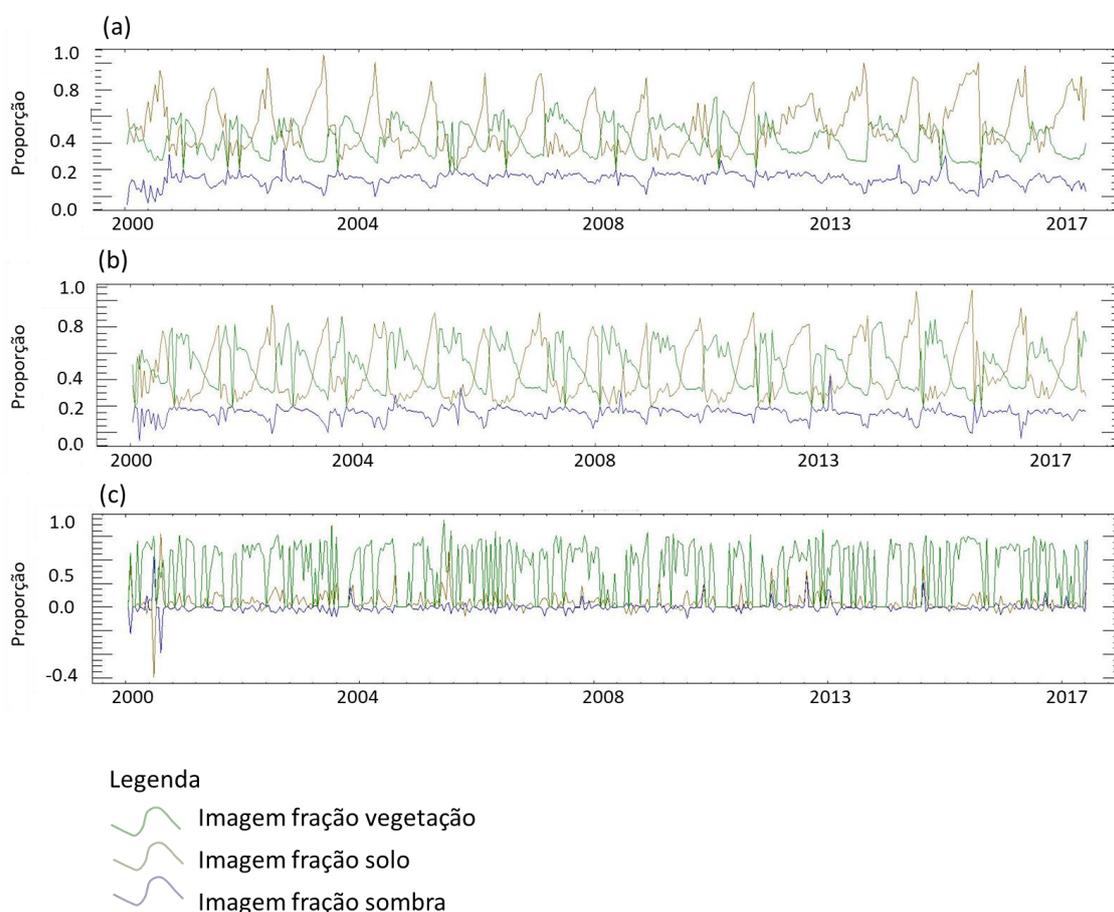
Deste modo, apenas algumas áreas foram selecionadas para observação sendo: vegetação nativa da Caatinga (5.12a), Cerrado (5.12b) e Mata Atlântica (5.12c), além de áreas em que foram observadas a conversão de vegetação natural da Caatinga para agricultura perene (5.14a), degradação da vegetação (5.14b) e assoreamento de corpos hídricos (5.14c).

Como já discutido anteriormente, os biomas presentes na Bahia apresentam características distintas como, por exemplo, a sazonalidade da vegetação nativa observada na CA e CE. Estas características, observadas na série temporal (Figuras 5.12a e 5.12b), ficam evidentes nas imagens fração quando as proporções das frações vegetação e solo são inversamente proporcionais. Ou seja, periodicamente há a maior proporção da fração solo e queda na proporção da fração vegetação relacionadas à queda foliar entre as espécies que são diretamente afetadas pela periodicidade das chuvas (REICH; BORCHERT, 1984; PAVÓN; BRIONES, 2001; JOLLY; RUNNING, 2004; SINGH; KUSHWAHA, 2005).

De acordo com Tomasella et al. (2018), a Caatinga exibe grandes variações no esverdeamento da vegetação, na cobertura e na mortalidade das árvores, tanto no espaço como no tempo, que se refletem diretamente nos valores de reflectância de superfície dos sensores orbitais. Além disso, o uso de vegetação lenhosa como fonte de energia é prática comum de manejo e provoca respostas espectrais complexas que variam de ano para ano.

Para o bioma Mata Atlântica (5.12c) não são observadas grandes variações nas proporções das frações, sendo características de vegetações sempre verde. Entretanto, por se tratar de regiões com alta incidência de nuvens, a filtragem de nuvens utilizada com a seleção de *pixels* com boa qualidade e qualidade duvidosa gera vários *pixels* sem valores de reflectância mesmo baseada em uma abordagem multitemporal, justificando às quedas das frações para zero em determinados períodos do ano.

Figura 5.12 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 para amostras de Caatinga, Cerrado e Mata Atlântica.

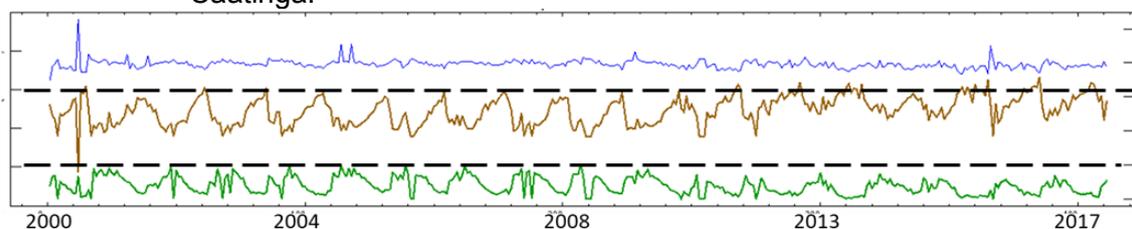


Exemplos de perfis temporais sem filtragem produzidos com as imagens fração vegetação, solo e sombra entre 2000 e 2017. Sendo: (a) vegetação de Caatinga; (b) Cerrado e (c) Mata Atlântica;

Fonte: Produção do autor.

A variação observada entre os perfis de CA e CE estão relacionadas às maiores proporções e amplitude da fração vegetação no CE, tendo o componente solo mais acentuado nos perfis de CA. Entretanto, observando os perfis temporais da vegetação em ambos os biomas, nota-se que houveram alterações nos padrões, justificadas nas proporções mais inferiores a partir de 2012 e 2013 coincidindo, mais uma vez, com o início da seca que atingiu a região. Essas alterações podem ser melhores visualizadas observando as imagens fração separadamente (Figuras 5.13).

Figura 5.13 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 observadas separadamente para amostra de Caatinga.



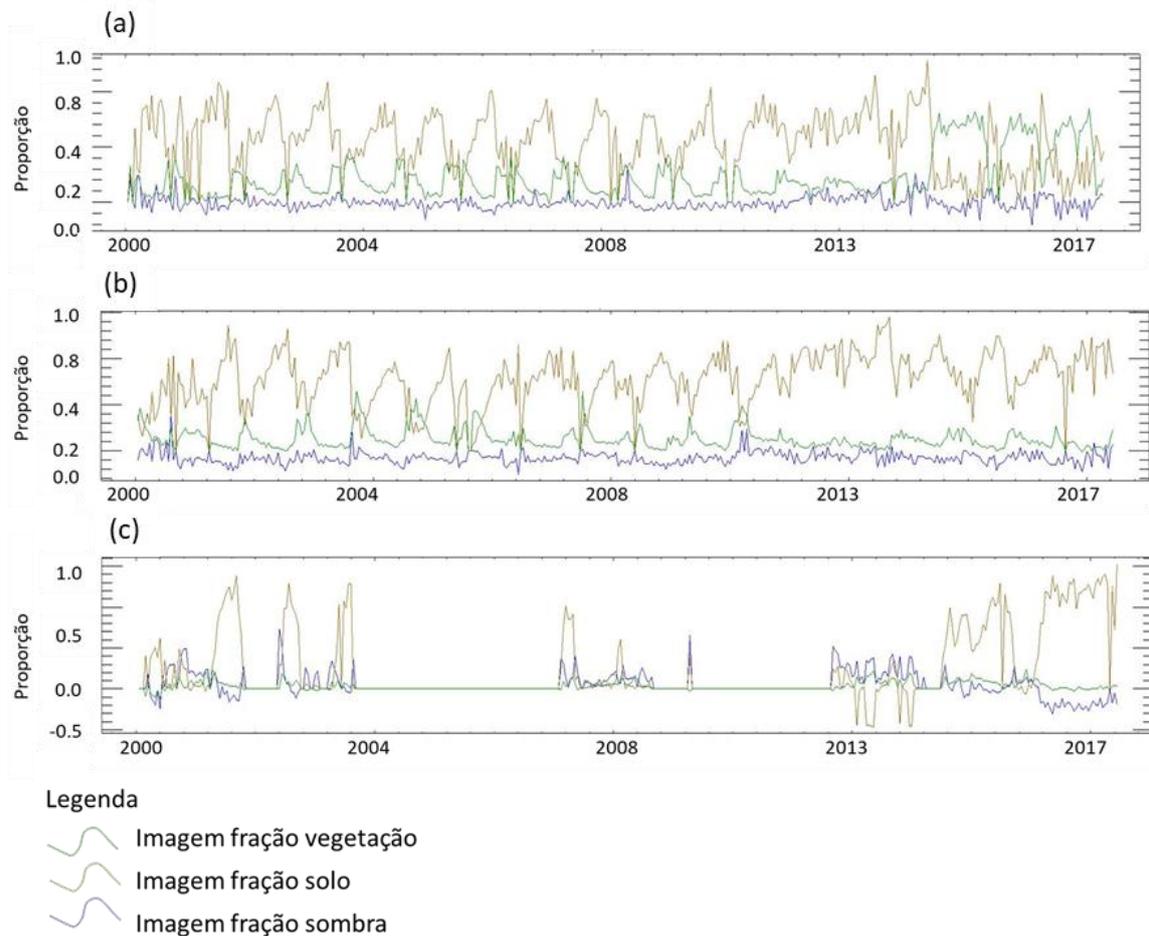
Sendo: (azul) imagem fração sombra; (marrom) imagem fração solo e (verde) imagem fração vegetação;

Fonte: Produção do autor.

A mudança nos padrões de vegetação e solo são observadas quando há a conversão de vegetação nativa para agricultura (Figura 5.14a e Tabela 5.9a), quando há redução da vegetação e aumento do solo (Figura 5.14b), bem como o aumento de solo em áreas de corpos hídricos (Figuras 5.14c, 5.15b e Tabela 5.9b). Estas duas últimas também são observadas principalmente a partir dos anos 2012 e 2013, corroborando com os impactos da seca.

Observa-se que nos perfis temporais obtidos em corpos hídricos (Figuras 5.14c e 5.15b), as proporções das imagens fração são apresentadas valores. Isso se deve ao processamento das imagens disponibilizadas do sensor MODIS, visto que em determinados corpos hídricos os *pixels* são mascarados, ou seja, classificados como não produzidos (Figura 3.3).

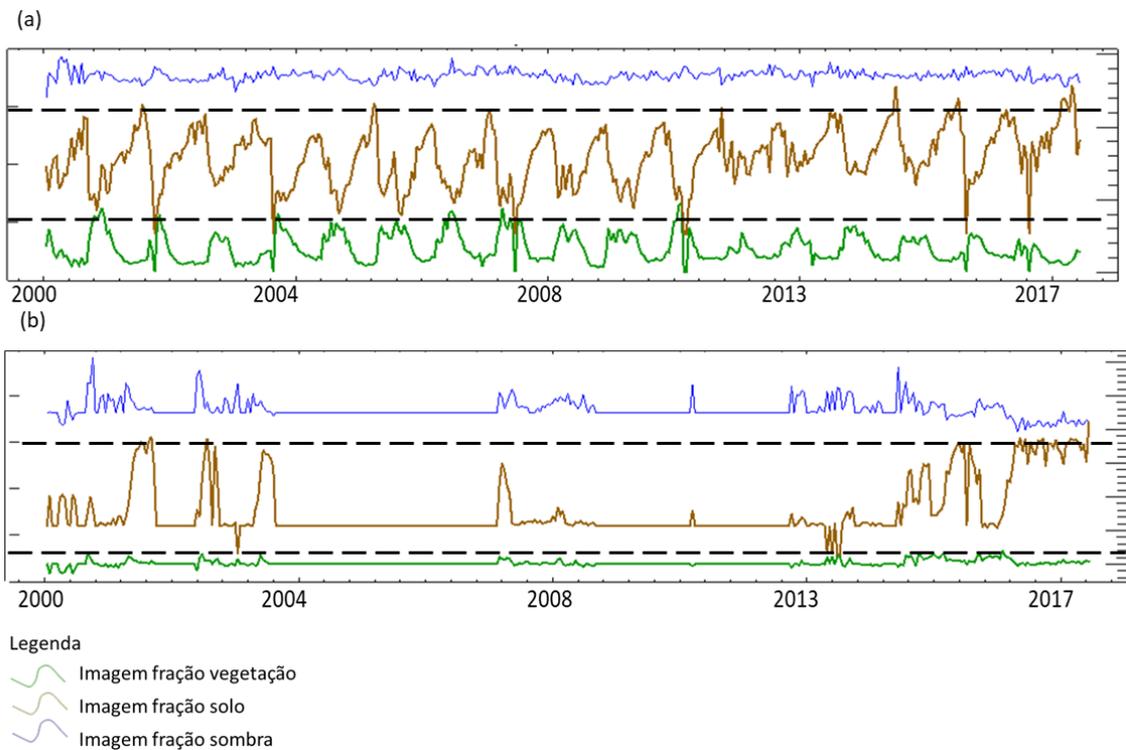
Figura 5.14 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 para amostras de conversão de vegetação natural da Caatinga para agricultura perene, degradação da vegetação e assoreamento de corpos hídricos.



Exemplos de perfis temporais produzidos sem filtragem com as imagens fração vegetação, solo e sombra entre 2000 e 2017. Sendo: (a) conversão de vegetação natural da Caatinga para agricultura perene; (b) degradação natural da Caatinga; (c) áreas de solo encontradas em corpos hídricos.

Fonte: Produção do autor.

Figura 5.15 – Perfis temporais das imagens fração vegetação, solo e sombra geradas entre 2000 e 2017 observadas separadamente em amostras de degradação da vegetação e assoreamento de corpos hídricos.



Exemplos de perfis temporais produzidos sem filtragem com as imagens fração vegetação, solo e sombra entre 2000 e 2017. Sendo: (a) degradação natural da Caatinga; (b) assoreamento de corpos hídricos.

Fonte: Produção do autor.

Tabela 5.9 – Exemplos de áreas de conversão da vegetação nativa da Caatinga em agricultura perene (a) e aumento de solo em corpos hídricos (b).

Imagens Google Earth 2000	Imagens Google Earth 2017
	
(a)	
	
(b)	

Onde (a) representa uma área de conversão da vegetação nativa da Caatinga em agricultura perene, localizada na porção Norte do estado (Latitude $9^{\circ}38'30''$ e Longitude $40^{\circ}32'48''$) e (b) exemplifica o assoreamento em parte da bacia do rio São Francisco, também localizado na porção Norte do estado (Latitude $-9^{\circ}56'10''$ e Longitude $-42^{\circ}10'13''$).

Fonte: Produção do autor.

Ao se tratar de perfis temporais com base em imagens orbitais, diversos métodos de suavização de curvas têm sido propostos, tais como a média móvel, a mediana, a transformada de Fourier, o filtro Savitzky-Golay ou a transformada de Wavelet (CHEN et al., 2004; CARVALHO Jr. et al., 2006;

BRADLEY et al., 2007; LU et al., 2007; GALFORD et al., 2008; HIRD; McDERMID, 2009; COUTO Jr. et al., 2012).

Cada método para de suavização apresenta vantagens e desvantagens, como exemplo, a média móvel é uma opção de fácil implementação e rápida execução, entretanto, os resultados deixam a desejar quando os dados apresentam picos estreitos (CERQUEIRA et al., 2000). Ainda segundo esses últimos autores, a transformada de Fourier tem como principal limitação as variações bruscas na série temporal, como, por exemplo, quando uma área de Cerrado remanescente é convertida em cultura agrícola (BORGES; SANO, 2014).

Alguns trabalhos sugerem, também, a não utilização de filtros e interpoladores no tempo, visto que estes processamentos podem gerar valores de preenchimento irrealistas, especialmente em vegetações tão impactadas pela sazonalidade (BRANDT et al., 2016). Entretanto, Borges e Sano (2014) apontam que a escolha do filtro mais adequado para a suavização de séries temporais constitui-se das etapas de pré-processamento que deve ser considerada em estudos que envolvam séries temporais.

Assim, o uso dos perfis temporais das imagens fração demonstram potencialidades para analisar a relação entre a resposta da vegetação e a influência dos fatores climáticos de precipitação e temperatura nos diferentes biomas do Nordeste, podendo ser empregadas análises estatísticas, algoritmos de séries temporais para extração de métricas e atributos de sazonalidade, como, por exemplo, o TIMESAT (EKLUNDH; JÖNSSON, 2012) e métodos capazes de detectar quebras de padrão no comportamento das tendências, como o BFAST (*Breaks For Additive Seasonal and Trend*) (VERBESSELT et al., 2010).

6 CONCLUSÕES E RECOMENDAÇÕES

O método utilizado nesta dissertação para estimar os *endmembers* demonstra o potencial do Modelo Linear de Mistura Espectral para relacionar informações provenientes de sensores com diferentes resoluções espaciais e espectrais. As análises realizadas demonstraram que as respostas espectrais estimadas permitiram a melhoria dos resultados no que se refere ao erro, à variabilidade e à identificação das proporções dos componentes, visto que a escolha indevida de *pixels* considerados como puros em produtos de baixa e moderada resolução espacial pode superestimar ou subestimar os resultados obtidos.

Quanto ao mapeamento da cobertura vegetal, o método proposto baseado nas imagens fração contendo o valor máximo das proporções, reduziu a dimensionalidade dos dados e realçou as classes de interesse. Este método possui a vantagem de considerar toda a série temporal de um ano, minimizando os efeitos de nuvens principalmente quando considerado o estado da Bahia, que apresenta este fator limitante nos mapeamentos atuais. Além disso, minimiza a influência da sazonalidade da vegetação nativa da Caatinga e Cerrado por não determinar únicos períodos secos e únicos períodos úmidos, que, por sua vez, variam ao longo do estado. Ao mesmo tempo, o método permitiu a extração de informações importantes relacionadas aos padrões das classes de uso e cobertura da terra ao longo de um período.

Embora os resultados tenham apresentado inconsistências na classificação de determinados tipos de cobertura, incertezas podem estar associadas à heterogeneidade da paisagem dentro de uma célula de 250 x 250 m do sensor utilizado, dificultando o mapeamento de pequenas alterações ambientais que podem não ser detectadas devido à resolução espacial. Por outro lado, a melhor resolução temporal aumentou a probabilidade de encontrar *pixels* sem a incidência de nuvens, sendo possível a extração de valores ao menos uma única vez ao ano, o que poderia não ocorrer em sensores com menor resolução temporal.

Outro fator está relacionado à dificuldade de separação das vegetações sazonais encontradas na Caatinga e Cerrado, também demonstrado por outros

trabalhos, e que, apresentam respostas espectrais semelhantes. Adicionado a este fator, observa-se que os eventos extremos de seca que têm atingido o Nordeste nos últimos anos, como o ocorrido entre 2012 e 2017, podem ter influenciado na confusão entre classes, especialmente as mais afetadas pela seca no semi-árido Nordestino.

Neste sentido, o uso da série temporal das imagens fração derivadas do Modelo Linear de Mistura Espectral para o monitoramento da vegetação, mostrou-se sensível para a detecção da sazonalidade e caracterização dos padrões das diferentes formações vegetais. Além disso, evidenciou a redução do componente vegetação e aumento do componente solo especialmente em anos caracterizados por eventos extremos de seca.

Com base nestas conclusões, as abordagens aqui apresentadas nesta dissertação abrem uma série de perguntas e hipóteses. Diante de um cenário de mudanças no uso e cobertura da terra e eventos extremos induzidos por oscilações climáticas, a região Nordeste pode ser considerada como um caso de estudo ideal para entender a magnitude dos impactos destas mudanças em ecossistemas tropicais e a sua relação com a vegetação.

Assim, recomenda-se para trabalhos futuros em relação à classificação: a separação de regiões com base nas tipologias climáticas para, então, determinar os períodos úmidos e secos para a melhor discriminação de classes. Uso de outras variáveis de entrada na classificação, como, por exemplo, a imagem fração NPV (*non-photosynthetic Vegetation*), altimetria, precipitação e outras variáveis estatísticas como o desvio padrão das imagens fração vegetação, solo e sombra. Além disso, recomenda-se a aquisição de dados de campo para coleta de amostras mais representativas da vegetação.

Em relação ao monitoramento por séries temporais, recomenda-se a utilização de métodos de suavização e interpoladores no tempo, assim como o uso de algoritmos para extração de métricas e detecção de mudanças. Sugere-se também o uso de dados de precipitação e temperatura para as análises relacionadas à resposta da vegetação em relação aos fatores abióticos.

Por fim, conclui-se que umas das principais potencialidades para o uso dos métodos aqui apresentados está na possibilidade de estender as informações das imagens fração contidas em escala local para estudos relacionados ao mapeamento e monitoramento do uso e cobertura da terra em escalas regional e global.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMI, M. **Estimativa da data de plantio da soja por meio de séries temporais de imagens MODIS**. 2010. 163p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <http://urlib.net/sid.inpe.br/mtcm19/2010/09.15.21.47>.
- ADAMI, M.; BERNARDES, S.; ARAI, E.; FREITAS, R.M.; SHIMABUKURO, Y.E.; ESPÍRITO-SANTO, F.D.; RUDORFF, B.F.; ANDERSON, L.O. Seasonality of vegetation types of South America depicted by moderate resolution imaging spectroradiometer (MODIS) time series. **International Journal of Applied Earth Observation and Geoinformation**, v.69, p.148-163, 2018.
- ALMAGRO, A.; OLIVEIRA, P.T.S.; NEARING, M.A.; HAGEMANN, S. Projected climate change impacts in rainfall erosivity over Brazil. **Nature Scientific Reports**, v.7, n.1, p.8130, 2017.
- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P. C.; GONÇALVES, J. L. M. Modeling monthly mean air temperature for Brazil. **Theoretical and Applied Climatology**, v.113, p.407–427, 2013.
- ANDERSON, L. O. **Classificação e monitoramento da cobertura vegetal do estado do Mato Grosso utilizando dados multitemporais do sensor MODIS**. 2004. 247p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 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.
- ANDERSON, L.O.; ARAGÃO, L.E.O.C.; ARAI, E. Avaliação dos dados de chuva mensal para a região amazônica oriundos do satélite tropical rainfall measuring mission (TRMM) produto 3b43 versões 6 e 7 para o período de 1998 a 2010. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013. **Anais...** São José dos Campos: INPE, 2013. p. 6743–6750.
- ANWAR, S.; STEIN, A. Detection and spatial analysis of selective logging with geometrically corrected Landsat images. **International Journal of Remote Sensing**, v.33, n.24, p.7820–7843, 2012. DOI:10.1080/01431161.2012.701378.

ARAGÃO, J. R. L.; ARAI, E.; SHIMABUKURO, Y. E. Preparação dos produtos MODIS para aplicações operacionais como o Projeto DETER (Detecção de áreas desflorestadas em tempo quase real). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 2531-2537. (INPE-15812-PRE/10422). Disponível em: <http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.12.34.07>.

ARAGÃO, L. E. O. C.; ANDERSON, L. O.; CAMPAHARO, W.A.; LOPES, A.P.; NEVES, A. K.; DUTRA, A. C.; SCALIONI, D.C.C.; PEREIRA, V.P.B. **Padrões e impactos dos incêndios florestais nos biomas brasileiros**. São José dos Campos: INPE, 2019. Em revisão.

ASNER, G.P. Cloud cover in landsat observations of the brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 2001.

ASNER, G.P.; KNAPP, D. E.; BROADBENT, E. N.; OLIVEIRA, P. J.; KELLER, M.; SILVA, J. N. Selective logging in the Brazilian Amazon. **Science**, v.310, n.5747, p.480-482, 2005. DOI: 10.1126/science.1118051.

ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DE ÓLEOS VEGETAIS - ABIOVE. **Moratória da soja**. Disponível em: <http://www.abiove.org.br/site>. Acesso em: 20 nov. 2017.

BAHIA. SECRETARIA DO MEIO AMBIENTE - SEMA. **Relatório anual**. 2017. Disponível em: <http://www.meioambiente.ba.gov.br/arquivos/File/0RelatorioSema.pdf>. Acesso em: 28 jan. 2018.

BASHIR, S.; QAMAR, U.; KHAN, F.H.; JAVED, M.Y. MV5: a clinical decision support framework for heart disease prediction using majority vote based classifier ensemble. **Arabian Journal for Science and Engineering**, v.39, n.11, p.7771-7783, 2014.

BELGIU, M.; DRĂGUȚ, L. *Random Forest* in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.114, p.24-31, 2016.

BELLE, V. **Detection and recognition of human faces using *Random Forest* for a mobile root**. 2008.104p. Dissertação (Mestrado em Ciência da Computação) – Rwthachen University, Alemanha, 2008.

BELLOT, F.-F.; BERTRAM, M.; NAVRATIL, P.; SIEGERT, F.; DOTZAUER, H. **The highresolution global map of 21st-century forest cover change from the University of Maryland (“Hansen Map”) is hugely overestimating deforestation in Indonesia (press release)**. 2014. Disponível em: http://www.forclime.org/images/documents/FORCLIME_Overestimation%20of%20Deforestation.pdf. Acesso em: 24 jan. 2018.

BEUCHLE, R.; GRECCHI, R.C.; SHIMABUKURO, Y.E.; SELIGER, R.; EVA, H.D.; SANO, E.; ACHARD, F. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach. **Applied Geography**, v.58, p.116–127, 2015.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry Remote Sensing**, v.65, p.2–16, 2010.

BORCHERT, R. Climate periodicity, phenology, and cambium activity in tropical dry forest trees. **Iawa Journal**, n. 20, p. 239-247, 1999.

BORCHERT, R.; RIVERA, G.; HAGNAUER, W. Modification of vegetative phenology in a tropical semi-deciduous forest by abnormal drought and rain. **Biotropica**, v.34, n.1, p.27-39, 2002.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p.526-547, 2014.

BRADLEY, B. A.; JACOB, R. W.; HERMANCE, J. F.; MUSTARD, J. F. A curve fitting procedure to derive inter-annual phenologies from time series of noisy satellite NDVI data. **Remote Sensing of Environment**, v. 106, n.2, p. 137-145, 2007.

BRANDT, M.; HIERNAUX, P.; RASMUSSEN, K.; MBOW, C.; KERGOAT, L.; TAGESSON, T.; FENSHOLT, R. Assessing woody vegetation trends in Sahelian drylands using MODIS based seasonal metrics. **Remote Sensing of Environment**, v. 183, p. 215-225, 2016.

BRANNSTROM, C.; JEPSON, W.; FILIPPI, A.; REDO, D.; XU, Z.; GANESH, S. Land change in the Brazilian savanna (Cerrado), 1986 e 2002: comparative analysis and implications for land-use policy. **Land Use Policy**, v.25, p.579-595, 2008.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE. **Mapeamento do uso e cobertura do cerrado**: projeto TerraClass Cerrado, 2013. Brasília: MMA, 2015. Disponível em: http://www.dpi.inpe.br/tccerrado/Metodologia_TCCerrado_2013.pdf. Acesso em: 27 jan. 2018.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Monitoramento do desmatamento nos biomas brasileiros por satélite**: acordo de cooperação técnica MMA/Ibama monitoramento do Bioma Caatinga 2008-2009. Brasília: MMA, 2011.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Caatinga**. 2017. Disponível em: <http://www.mma.gov.br/biomas/caatinga>.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Mapas de cobertura vegetal dos biomas brasileiros**. 2014. Disponível em <http://mapas.mma.gov.br/mapas/aplic/probio/datadownload.htm>. Acesso em: 25 jan. 2018.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Monitoramento do desmatamento nos biomas brasileiros por satélite: cerrado: relatório final**. 2015. Disponível em: http://siscom.ibama.gov.br/monitora_biomass/PMDBBS%20-%20CERRADO.html. Acesso em: 25 jan. 2018.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Mapas de cobertura vegetal dos biomas brasileiros**. 2014. Disponível em <http://mapas.mma.gov.br/mapas/aplic/probio/datadownload.htm>. Acesso em: 25 jan. 2018.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Monitoramento do desmatamento nos biomas brasileiros por satélite: cerrado: relatório final**. 2015. Disponível em: http://siscom.ibama.gov.br/monitora_biomass/PMDBBS%20-%20CERRADO.html. Acesso em: 25 jan. 2018.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Monitoramento do desmatamento nos biomas brasileiros por satélite: acordo de cooperação técnica MMA/Ibama Monitoramento do bioma Caatinga 2008-2009**. Brasília: MMA, 2011.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **PROBIO e projeto de conservação e utilização sustentável da diversidade biológica brasileira: subprojeto e levantamento da cobertura vegetal e do uso do solo do bioma Caatinga: relatório final**. Brasília: MMA, [20--].

BREIMAN, L. Random Forests. **Machine Learning**, v.45, n.1, p.5-32, 2001.

BREIMAN, L.; FRIEDMAN, J.; STONE, C.J.; OLSHEN, R.A. **Classification and regression trees**. [S.l.]: CRC press, 1984.

BRESHEARS, D. The grassland–forest continuum: trends in ecosystem properties for woody plant mosaics? **Frontiers in Ecology and the Environment**, v.4, p.96–104, 2006.

BRITO, S.S.B.; CUNHA, A.P.M.A.; CUNNINGHAM, C.C.; ALVALÁ, R.C.; MARENGO, J.A.; CARVALHO, M.A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v.38, n.2, p.517-529, 2018.

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

CÂMARA, G.; SOTERRONI, A.; RAMOS, F.; CARVALHO, A.; ANDRADE, P.; SOUZA, R.; MOSNIER, A.; MANT, R.; BUURMAN, M.; PENA, M.; HAVLIK, P.; PIRKER, J.; KRAXNER, F.; OBERSTEINER, M.; KAPOS, V.; AFFONSO, A.; ESPÍNDOLA, G.; BOCQUEHO, G. **Modelling land use changes in Brazil 2000-2050**. São José dos Campos: INPE, 2015.

CANAVESI, V.; COURA, S.D.C.; FORMAGGIO, A.R.; SHIMABUKURO, Y.E.; QUIRINO, V.F. Dinâmica espectro-temporal MODIS em região de Cerrados e intenso uso agropecuário. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005. **Anais...** São José dos Campos: INPE, 2005.

CARVALHO JUNIOR, O.A.; HERMUCHE, P.M.; GUIMARÃES, R.F. Identificação regional da floresta estacional decidual na bacia do Rio Paraná a partir da análise multitemporal de imagens MODIS. **Revista Brasileira de Geofísica**, v.24, n.3, p. 319-332, 2006.

CASTELLETTI, C. H. M.; SILVA, J. M. C. D.; TABARELLI, M.; SANTOS, A. M. M. Quanto ainda resta da Caatinga? In: SILVA, J.M.C.D.; TABARELLI, M.; FONSECA, M.T.D.; LINS, L. V. (Eds.). **Uma estimativa preliminar da biodiversidade da Caatinga: áreas e ações prioritárias para a conservação**. Brasília, DF: Ministério do Meio Ambiente, 2003.

CERQUEIRA, E. O.; POPPI, R. J.; KUBOTA, L. T. Utilização de filtro de transformada de Fourier para a minimização de ruídos em sinais analíticos. **Química Nova**, v. 23, n.5, p.690-698, 2000.

CHEN, J. et al. Global land cover mapping at 30 m resolution: a POK-based operational approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.103, p.7–27, 2015.

CHEN, J.; JONSSON, P.; TAMURA, M.; GU, Z.; MATSUSHITA, B.; EKLUNDH, L. A simple method for reconstructing a high-quality NDVI timeseries data set based on the Savitzky-Golay filter. **Remote Sensing of Environment**, v. 91, p. 332-344, 2004.

CHUINE, I.; CAMBON, G.; COMTOIS, P. Scaling phenology from the local to the regional level: advances from species-specific phenological models. **Global Change Biology**, v.6, n.8, p.943-952, 2000.

CLARK, M.L.; AIDE, T.M. Virtual Interpretation of Earth Web-Interface Tool (VIEW-IT) for collecting land-use/land-cover reference data. **Remote Sensing**, v.3, n.3, p.601-620, 2011.

COSTA, H.; FOODY, G.M.; BOYD, D.S. Supervised methods of image segmentation accuracy assessment in land cover mapping. **Remote Sensing of Environment**, v.205, p.338-351, 2018.

COSTA, O.V.; COSTA, L.D.; FONTES, L.E.F.; ARAUJO, Q.R.; KER, J.C.; NACIF, P.G.S. Cobertura do solo e degradação de pastagens em área de domínio de Chernossolos no sul da Bahia. **Revista Brasileira de Ciência do Solo**, v.24, n.4, 2000.

COSTA, W. S. **Mapeamento de formações campestres nativas e de pastagens cultivadas no cerrado Brasileiro utilizando mineração de dados**. 2014. 85p. Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014.

COUTINHO, A. C.; ESQUERDO; J. C. D. M.; DE OLIVEIRA, L.S.; LANZA, D.A.; RONDON, A.C.; CALÓGERAS, R.J.P. Avaliação de metodologia para o mapeamento e monitoramento da agricultura brasileira. In: SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 4., 2012, Bonito, MS. **Anais...** Embrapa Informática Agropecuária; INPE, 2012. p.364-372.

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, p. 405-418, 2012.

CUNHA, A.P.M.; ALVALÁ, R.C.; NOBRE, C.A.; CARVALHO, M.A. Monitoring vegetative drought dynamics in the Brazilian semiarid region. **Agricultural and Forest Meteorology**, v. 214, p.494-505, 2015.

DE ALCANTARA, E.H.; STECH, J.L.; NOVO, E.M.L.M.; SHIMABUKURO, Y.E.; BARBOSA, C.C.F. Turbidity in the Amazon floodplain assessed through a spatial regression model applied to fraction images derived from MODIS/Terra. **IEEE Transactions on Geoscience and Remote Sensing**, v.46, n.10, p.2895-2905, 2008.

DIDAN, K.; MUNOZ, A.B.; SOLANO, R.; HUETE, A. **MODIS vegetation index user's guide (MOD13 series)**. Tucson: The University of Arizona, 2015. p.1-38.

DOURADO, C.D.S. **Áreas de risco de desertificação: cenários atuais e futuros, frente às mudanças climáticas**. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual de Campinas, Campinas – SP, 2017. Disponível em: <http://www.repositorio.unicamp.br/handle/REPOSIP/330998>. Acesso em: 3 set. 2018.

DUTRA, A. C.; SHIMABUKURO, Y. E.; ARAI, E. Aplicação do modelo linear de mistura espectral por abordagem combinada entre resoluções espaciais de imagens do sensor PROBA-V. In: SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 7., 2018, Jardim, MS. **Anais...** São José dos Campos: INPE, 2018. p. 122-130. Disponível em <https://www.geopantanal.cnptia.embrapa.br/2018/pdfs/p16.pdf>. ISBN 978-85-17-00094-2. Acesso em: 19 out. 2018.

DUTRA, A. C.; SHIMABUKURO, Y. E.; ARAI, E.; DUARTE, V.; GASPARINI, K. A. C.; SANTOS, E. G. Imagens fração derivadas das imagens Proba-V para mapear o uso e cobertura da terra no estado do Mato Grosso. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2019b. Aceito.

DUTRA, A. C.; SHIMABUKURO, Y. E.; ESCADA, M. I. S. Data mining using NDVI time series applied to change detection. **Proceedings**, v.2, n.356, 2018.

DUTRA, A.C; SHIMABUKURO, Y. E.; ARAI, E. Linear spectral mixing model applied to multi spatial resolution images from Proba-V sensor. **Revista Geografia**, 2019a. Aceito.

DUTRA, A.C; VIEIRA, D.C.; MONTIBELLER, B.; MOREIRA, M.A.; SANCHES, I. DEL'A.; SHIMABUKURO, Y. E. Influência da expansão das áreas de soja na mudança de cobertura da terra no município de Luís Eduardo Magalhães, Bahia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2019c. Aceito.

EKLUNDH, L.; JÖNSSON, P. **TIMESAT 3.2 with parallel processing**: software manual. Lund: Lund University, 2012. 88p.

ESPINOZA, J.C.; MARENGO, J.A.; RONCHAIL, J.; CARPIO, J.M.; FLORES, L.N.; GUYOT, J.L. The extreme 2014 flood in south-western Amazon basin: the role of tropical-subtropical South Atlantic SST gradient. **Environmental Research Letters**, v. 9, n. 12, 2014.

ESQUERDO, J.C.D.M.; COUTINHO, A.C.; SANCHES, L.B.; RIBEIRO, B.D.O.; ZAKHAROV, N.Z.; TERRA, T.N; MANABE, V.D. Dinâmica da agricultura anual na região do Matopiba. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17, 2015. **Anais...** São José dos Campos: INPE, 2015.

FRANCISCO, P. R. M.; BRITO CHAVES, I.; LIMA, E. R. V.; BANDEIRA, M. M.; SILVA, B. B. Mapeamento da Caatinga com uso de geotecnologia e análise da umidade antecedente em bacia hidrográfica. **Revista Brasileira de Geografia Física**, v.5, n.3, p.676-693, 2012.

FAN, F.; DENG, Y. Enhancing endmember selection in multiple endmember spectral mixture analysis (MESMA) for urban impervious surface area mapping using spectral angle and spectral distance parameters. **International Journal of Applied Earth Observation and Geoinformation**, v.33, p.290-301, 2014.

FANG, X.; ZHU, Q.; REN, L.; CHEN, H.; WANG, K.; PENG, C. Large-scale detection of vegetation dynamics and their potential drivers using MODIS images and BFAST: a case study in Quebec, Canada. **Remote Sensing of Environment**, v.206, p.391-402, 2018.

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.

FEARNSIDE, P.M. Soybean cultivation as a threat to the environment in Brazil. **Environment Conservation**, v.28, n.1, p.23-38, 2001.

FEARNSIDE, P.M. Amazonian deforestation and global warming: carbon stocks in vegetation replacing Brazil's Amazon forest. **Forest Ecology and Management**, v.80, n.1/3, p.21-34, 1996.

FERNANDES, M. F.; QUEIROZ, L. P. DE. Vegetação e flora da Caatinga. **Ciência e Cultura**, São Paulo, v.70, n.4, p.51-56, Oct. 2018.

FIGUEIREDO, P. S. Fenologia e estratégias reprodutivas das espécies arbóreas em uma área marginal de cerrado, na transição para o semi-árido no nordeste do Maranhão, Brasil. **Revista Trópica: Ciências Agrárias e Biológicas**, Chapadina, v. 2, n. 2, p.8-22, 2008.

FISCALIZAÇÃO PREVENTIVA INTEGRADA - FPI. **Velho Chico: a experiência da Fiscalização Preventiva Integrada na Bahia**. Salvador: Ministério Público da Bahia; FPI, 2014. 430p. ISBN 978-85-98936-04-5.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **Trees, forests and land use in drylands: the first global assessment**. Rome: FAO, 2016.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. **Map accuracy assessment and area estimation map accuracy assessment and area estimation: a practical guide**. Disponível em: <http://www.fao.org/3/a-i5601e.pdf>.

FORMIGONI, M. 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.

FRANCA-ROCHA, W.J.S.; CHAVES, J.M. **Caatinga biome ATBD_R collection 2.1**. MAPBIOMAS, 2017. Disponível em: <http://mapbiomas.org/>.

FUNDAÇÃO SOS MATA ATLÂNTICA; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Atlas dos remanescentes florestais da Mata Atlântica**. São Paulo: Fundação SOS Mata Atlântica, 2017. Disponível em: <http://mapas.sosma.org.br/site_media/download/atlas_2015-2016_relatorio_tecnico_2017.pdf>. Acesso em: 27 jan. 2018.

GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C.; CERRI, C. E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, v. 112, p. 576-587, 2008.

GARCÍA-HARO, F.J.; SOMMER, S.; KEMPER, T. Variable multiple endmember spectral mixture analysis (VMESMA): a high-performance computing and environment analysis tool. **International Journal of Remote Sensing**, v.26, n.10, p.2135-2162, 2005.

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**. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

GÓMEZ, C.; WHITE, J.; WULDER, M.A. Optical remotely sensed time series data for land cover classification: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.116, p.55-72, 2016.

HANSELMANN, M.; KÖTHE, U.; KIRCHNER, M.; RENARD, B.Y.; AMSTALDEN, E.R.; GLUNDE, K.; HEEREN, R.M.; HAMPRECHT, F.A. **Towards digital staining using imaging mass spectrometry and *Random Forests***:technical report. [S.l.: s.n.], 2009. Disponível em: https://pdfs.semanticscholar.org/6263/126eeba268bae489ec3a8dea20a6742297ee.pdf?_ga=2.261943245.1786478611.1553615260-1923149023.1550676263.

HANSEN, M.C. Classification trees and mixed *pixel* training data. In: GIRI, C. P. (Ed.). **Remote sensing of land use and land cover: principles and applications**. Boca Raton: CRC Press, 2012. p.127–136.

HANSEN, M.C.; POTAPOV, P.V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S.V.; GOETZ, S.J.; LOVELAND, T.R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C.O.; TOWNSHEND, J.R.G. High-resolution global maps of 21st-century forest cover change. **Science**, v.342, p.850–853, 2013.

HANSEN, M.C.; ROY, D.P.; LINDQUIST, E.; ADUSEI, B.; JUSTICE, C.O.; ALTSTATT, A. A method for integrating MODIS and Landsat data for systematic monitoring of forest cover and change in the Congo Basin. **Remote Sensing of Environment**, v.112, n.5, p.2495-2513, 2008.

HILKER, T.; WULDER, M.A.; COOPS, N.C.; LINKE, J.; MCDERMID, G.; MASEK, J.G.; GAO, F.; WHITE, J.C. A new data fusion model for high spatial- and temporal-resolution mapping of forest disturbance based on Landsat and MODIS. **Remote Sensing of Environment**, v.113, n.8, p.1613-1627, 2009.

HIRAKURI, M.H.; CASTRO, C.D.; FRANCHINI, J.C.; DEBIASI, H.; PROCOPIO, S.D.O.; BALBINOT JUNIOR, A.A. **Indicadores de sustentabilidade da cadeia produtiva da soja no Brasil**. Warta: Embrapa Soja, 2014.

- HIRD, J. N.; McDERMID, G. J. Noise reduction of NDVI time-series: an empirical comparison of selected techniques. **Remote Sensing of Environment**, v.113, p.248-258, 2009.
- HUETE, A. R.; 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.1/2, p.195-213. 2002.
- HUETE, A. R.; JACKSON, R. D. Soil and atmosphere influences on the spectra of partial canopies. **Remote Sensing of Environment**, v.25, p.89–105, 1988.
- HUETE, A.R. A Soil Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v.25, p.295-309, 1988.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual técnico da vegetação brasileira**. Rio de Janeiro: IBGE, 2012.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Mapa de biomas e de vegetação**. Disponível em: <https://ww2.ibge.gov.br/home/presidencia/noticias/21052004biomashtml.shtm>. Acesso em: 27 jan. 2018.
- INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA. **PMDBBS: Projeto de Monitoramento do Desmatamento dos Biomas Brasileiros por Satélite**. Disponível em: http://siscom.ibama.gov.br/monitora_biomass/Metodologi_a%20-%20PMDBBS%20.html. Acesso em: 25 jan. 2018.
- INSTITUTO DO MEIO AMBIENTE E RECURSOS HÍDRICOS - INEMA. **Mapa da vegetação da Bahia**. 2014. Disponível em: <http://www.inema.ba.gov.br/servicos/mapas-tematicos/>. Acesso em: 24 jan. 2018.
- INSTITUTO NACIONAL DE CIÊNCIA E TECNOLOGIA PARA MUDANÇAS CLIMÁTICAS - INCT. **Desastres naturais**: – tema integrador 7. 2016. Disponível em: http://www.fapesp.br/eventos/2016/09/inct/REGINA_ALVALA.pdf.
- JACQUES, D.C.; KERGOAT, L.; HIERNAUX, P.; MOUGIN, E.; DEFOURNY, P. Monitoring dry vegetation masses in semi-arid areas with MODIS SWIR bands. **Remote Sensing of Environment**, v.153, p.40-49, 2014.
- JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009.

JOLLY, W. M.; RUNNING, S. W. Effects of precipitation and soil water potential on drought deciduous phenology in the Kalahari. **Global Change Biology**, v.10, n.3, p.303-308, 2004.

JUSTINIANO, M. J.; FREDERICKSEN, T. S. Phenology of tree species in Bolivian dry forests. **Biotropica**, v.32, n.2, p.276-281, 2000.

KESHAVA, N.; MUSTARD, J. F. Spectral unmixing. **IEEE Signal Processing Magazine**, v.19, n.1, p.44-57, 2002. DOI:10.1109/79.974727.44-57.

KO, D.; BRISTOW, N.; GREENWOOD, D.; WEISBERG, P. Canopy cover estimation in semiarid woodlands: comparison of field-based and remote sensing methods. **Forest Science**, v.55, p.132-141, 2009.

KOPPEN, W.P. **Das geographische system der klimate**. Berlin: Verlag von Gebrüder Borntraeger, 1936. 44p. (Handbuch der klimatologie).

KÖRTING, T.S. **GEODMA**: a toolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

KOUSKY, V.E. Frontal influences on northeast Brazil. **Monthly Weather Review**, v.107, n.9, p.1140-1153, 1979.

LABORATÓRIO DE PROCESSAMENTO DE IMAGENS E GEOPROCESSAMENTO - LAPIG. **Histórico**. Disponível em: <https://www.lapig.iesa.ufg.br/lapig/index.php/lapig/historico>. Acesso em: 27 jan. 2018.

LAMBIN, E.F. Modeling and monitoring land-cover changes processes in tropical regions. **Progress in Physical Geography**, v.2, n.3, p.375-393, 1997.

LAROSE, D. T.; LAROSE, C. D. **Discovering knowledge in data: an introduction to data mining**. 2.ed. [S.l.]: John Wiley and Sons, 2014.

LAWRENCE, R.L.; WOOD, S.D.; SHELEY, R.L. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (Random Forest). **Remote Sensing of Environment**, v.100, n.3, p.356-362, 2006.

LEAL, I. R; TABARELLI, M; SILVA, J. M. **Ecologia e conservação da caatinga**. Recife: UFPE, 2003. 822 p.

LEE, R.; YU, F.; PRICE, K.P. Evaluating vegetation phenological patterns in Inner Mongolia using NDVI time-series analysis. **International Journal of Remote Sensing**, v. 23, n. 12, p. 2505-2512, 2002.

LI, W.; BARET, F.; WEISS, M.; BUIS, S.; LACAZE, R.; DEMAREZ, V.; DEJOUX, J.F.; BATTUDE, M.; CAMACHO, F. Combining hectometric and decametric satellite observations to provide near real time decametric fapar product. **Remote Sensing of Environment**, v. 200, p. 250–262, 2017.

LIMOUSIN, J.M.; RAMBAL, S.; OURCIVAL, J.M.; ROCHETEAU, A.; JOFFRE, R.; RODRÍGUEZ- CORTINA, R. Long-term transpiration change with rainfall decline in a Mediterranean Quercus ilex forest. **Global Change Biology**, v.15, p.2163–2175, 2009.

LU, X.; LIU, R.; LIU, J.; LIANG, S. Removal of noise by wavelet method to generate high quality temporal data of terrestrial MODIS products. **Photogrammetric Engineering & Remote Sensing**, v.73, n.10, p.1129-1139, 2007.

MA, X.; HUETE, A.; MORAN, S.; PONCE-CAMPOS, G.; EAMUS, D. Abrupt shifts in phenology and vegetation productivity under climate extremes. **Journal of Geophysical Research: Biogeosciences**, v.120, n.10, p.2036-2052, 2015.

MACHADO, C.B. **Análise fenológica do dossel da floresta nacional do tapajós utilizando dados orbitais do sensor modis e hiperespectrais locais**. 143p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

MACHADO, I. C. S.; BARROS, L. M.; SAMPAIO, E. V. S. B. Phenology of Caatinga species at Serra Talhada, PE, Northeastern Brazil. **Biotropica**, v.29, n.1, p.57-68, 1997

MALDONADO, F. D. **Análise por Componentes Principais (ACP) na caracterização da dinâmica do uso da terra em área do semi-árido brasileiro: Quixaba-PE**. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999.

MARENGO, J.A.; CUNHA, A.P.; ALVES, L.M. A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico. **Climanálise**, v.3, p.1-6, 2016.

MARENGO, J.A.; JONES, R.; ALVES, L.M.; VALVERDE, M.C. Future change of temperature and rainfall extremes in South America as derived from the PRECIS regional climate modeling system. **International Journal of Climatology**, v.29, n.15, p. 2241-2255, 2009.

MARTINY, N.; RICHARD, Y.; CAMBERLIN, P. Interannual persistence effects in vegetation dynamics of semi-arid Africa. **Geophysical Research Letters**, v.32, n.24, 2005.

MEDEIROS, P.N.; OLIVEIRA E.; PAES, J. B. Relações entre as características da madeira e do carvão vegetal de duas espécies da caatinga. **Floresta e Ambiente**, v.21, n.4, p.484-493, 2014. Disponível em: <http://dx.doi.org/10.1590/2179-8087.051313>.

MOLION, L.C.B.; BERNARDO, S.O. Uma revisão da dinâmica das chuvas no nordeste brasileiro. **Revista Brasileira de Meteorologia**, v.17, p.1-10, 2002.

MORAIS, R. M.; CUNHA, M. C. L; SANTANA, G. M; PAES, J. B. Dendrological characterization as inspection resources of Caatinga wood market. **Floresta Ambiente**, v.25, n.3, 2018.

NEPSTAD, D.; LEFEBVRE, P.; DA SILVA, U. L.; TOMASELLA, J.; SCHLESINGER, P.; SOLORZANO, L.; MOUTINHO, P.; RAY, D.; BENITO, J. G. Amazon drought and its implications for forest flammability and tree growth: a basin-wide analysis. **Global Change Biology**, v. 10, n. 5, p. 704-717, 2004.

NEPSTAD, D.; MCGRATH, D.; STICKLER, C.; ALENCAR, A.; AZEVEDO, A.; SWETTE, B.; BEZERRA, T.; DIGIANO, M.; SHIMADA, J.; DA MOTTA, R.S.; ARMIJO, E. Slowing Amazon deforestation through public policy and interventions in beef and soy supply chain. **Science**, v.344, n.6188, p.1118-1123, 2014.

NICHOLSON, S.E.; TUCKER, C.J.; BA, M.B. Desertification, drought and surface vegetation: an example from the West African Sahel. **Bulletin of the American Meteorological Society**, v.79, p. 815-829, 1988.

NOLTE, C.; DE WAROUX, Y.L.P.; MUNGER, J.; REIS, T.N.; LAMBIN, E.F. Conditions influencing the adoption of effective anti-deforestation policies in South America's commodity frontiers. **Global Environmental Change**, v.43, p.1-14, 2017.

NOVO, E. M. M. **Sensoriamento remoto: princípios e aplicações**. 4 ed. São Paulo: Bluncher, 2010. 387p.

OLIVEIRA, P. E. Fenologia e biologia reprodutiva das espécies de Cerrado. In: SANO, S. M.; ALMEIDA, S. P. (Ed.) **Cerrado: ambiente e flora**. Planaltina: EMBRAPA-CPAC, 2008. p.169 – 188.

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 of Environment**, v.148, p.42–57, 2014.

PALHARINI, A.; SANTOS, R.; VILA, D.A. Climatological behavior of precipitating clouds in the northeast region of Brazil. **Advances in Meteorology**, v.2017, 5916150, 2017. DOI: 10.1155/2017/5916150.

PAUDEL, K. P.; ANDERSEN, P. Assessing rangeland degradation using multi temporal satellite images and grazing pressure surface model in Upper Mustang, Trans Himalaya, Nepal. **Remote Sensing of Environment**, v.114, p.1845–1855, 2010.

PAUSAS, J.G. Changes in fire and climate in the eastern Iberian Peninsula (Mediterranean basin). **Climatic Change**, v.63, p. 337-350, 2004.

PENNINGTON, R.T.; LEWIS, G. P.; RATTER, J. A. **Neotropical savannas and seasonally dry forests**. Boca Raton: CRC Press, 2006.

PETUS, C.; LEWIS, M.; WHITE, D. Monitoring temporal dynamics of Great Artesian Basin wetland vegetation, Australia, using MODIS NDVI. **Ecological Indicators**, v.34, p.41–52, 2013.

PHILIPPON, N.; MOUGIN, E.; JARLAN, L.; FRISON, P.-L. Analysis of the linkages between rainfall and land surface conditions in the West African monsoon trough CMAP, ERS-WSC, and NOAA-AVHRR data. **Journal of Geophysical Research**, v.110, n.D24, p.40-54, 2005.

PIRES, G.F.; ABRAHÃO, G.M.; BRUMATTI, L.M.; OLIVEIRA, L.J.; COSTA, M.H.; LIDDICOAT, S.; KATO, E.; LADLE, R.J. Increased climate risk in Brazilian double cropping agriculture systems: implications for land use in Northern Brazil. **Agricultural and Forest Meteorology**, v.228, p.286-298, 2016.

PIROMAL, R.A.S. **Avaliação do modelo 5-scale para simular valores de reflectância de unidades de paisagem da Floresta Nacional do Tapajós**. 151f. 2006. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

PITHON, S.; JUBELIN, G.; GUITET, S.; GOND, V. A statistical method for detecting logging-related canopy gaps using high-resolution optical remote sensing. **International Journal of Remote Sensing**, v.34, n.2, p.700–711, 2013. DOI:10.1080/01431161.2012.706719.

PONZONI, F. J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Parêntese, 2010. 127 p.

POULTER, B.; FRANK, D.; CIAIS, P.; MYNENI, R.B.; ANDELA, N.; BI, J.; BROQUET, G.; CANADELL, J.G.; CHEVALLIER, F.; LIU, Y.Y.; RUNNING, S.W. Contribution of semi-arid ecosystems to interannual variability of the global carbon cycle. **Nature**, v.509, n.7502, p.600, 2014.

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-MANSO, O.; SHIMABUKURO, Y. E. Mapping burned areas in mediterranean countries using spectral mixture analysis from a uni-temporal perspective. **International Journal of Remote Sensing**, v.27, n.4, p.645–662, 2006.

R DEVELOPMENT CORE TEAM. **R**: a language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing, 2008. Disponível em: <http://www.Rproject.org>. Acesso em: 10 fev. 2018.

REDO, D.; AIDE, T. M.; CLARK, M. L. Vegetation change in Brazil's dryland ecoregions and the relationship to crop production and environmental factors: Cerrado, Caatinga, and Mato Grosso, 2001–2009. **Journal of Land Use Science**, v.8, n.2, p.123-153, 2013.

REICH, P. B.; BORCHERT, R. Water stress and tree phenology in a tropical dry forest in the lowlands of Costa Rica. **Journal of Ecology**, v.72, n.1, p.61-74, 1984.

REYNOLDS, J.F.; SMITH, D.M.S.; LAMBIN, E.F.; TURNER, B.L.; MORTIMORE, M.; BATTERBURY, S.P.J.; DOWNING, T.E.; DOWLATABADI, H.; FERNÁNDEZ, R.J.; HERRICK, J.E.; HUBER-SANNWALD, E.; JIANG, H.; LEEMANS, R.; LYNAM, T.; MAESTRE, F.T.; AYARZA, M.; WALKER, B. Global desertification: building a science for dryland development. **Science**, v.316, p.847–851, 2007.

RICHARDSON, A.D.; HUFKENS, K.; MILLIMAN, T.; AUBRECHT, D.M.; CHEN, M.; GRAY, J.M.; JOHNSTON, M.R.; KEENAN, T.F.; KLOSTERMAN, S.T.; KOSMALA, M.; MELAAS, E.K. Tracking vegetation phenology across diverse North American biomes using PhenoCam imagery. **Nature Scientific Data**, v.5, p.180028, 2018.

RODRÍGUEZ-PUEBLA, C.; AYUSO, S.M.; FRÍAS, M.D.; GARCÍA-CASADO, L. A. Effects of climate variation on winter cereal production in Spain. **Climate Research**, v.34, n.3, p. 223-232, 2007.

ROTENBERG, E.; YAKIR, D. Contribution of semi-arid forests to the climate system. **Science**, v.327, p.451–454, 2010.

RUDORFF, B.F.T.; AGUIAR, D.A.; SILVA, W.F.; SUGAWARA, L.M.; ADAMI, M.; MOREIRA, M.A. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo State (Brazil) using Landsat data. **Remote Sensing**, v.2, p. 1057-1076, 2010.

SAMPAIO, E.V.A.; MARIA DO SOCORRO, B.A.; SAMPAIO, Y.S. Impactos ambientais da agricultura no processo de desertificação no Nordeste do Brasil. **Revista de Geografia**, v.22, n.1, p.90-112, 2005.

SANO, E.E.; FERREIRA, L.G.; ASNER, G.P.; STEINKE, E.T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v.28, n.12, p.2739-2752, 2007.

SANTOS, C. C. M. Oeste da Bahia: modernização com (dê)s articulação econômica e social de uma região. **Revista Ciências da Bahia**, v.31, p.17-49, 2007.

SANTOS, J.C.; LEAL, I.R.; CORTEZ, J.S.A.; FERNANDES, G.W.; TABARELLI, M. Caatinga: the scientific negligence experienced by a dry tropical forest. **Tropical Conservation Science**, v.4, n.3, p.276-286, 2011.

SCHWINNING, S.; SALA, O.E. Hierarchy of responses to resource pulses in arid and semi-arid ecosystems. **Oecologia**, v.141, p.211–220, 2004.

SESNIE, S. E.; FINEGAN, B.; GESSLER, P. E.; THESSLER, S.; BENDANA, Z. R.; SMITH, A. M. S. The multispectral separability of Costa Rican rainforest types with support vector machines and Random Forest decision trees. **International Journal of Remote Sensing**, v. 31, n. 11, p. 2885-2909, 2010.

SETTELE, J., SCHOLLES, R., BETTS, R., BUNN, S., LEADLEY, P., NEPSTAD, D.; OVERPECK, J.T.; TABOADA, M.A. Terrestrial and inland water systems. In: FIELD, C. B.; BARROS, V. R.; DOKKEN, D.J.; MACH, K. J.; MASTRANDREA, M. D.; BILIR, T. E.; CHATTERJEE, M.; EBI, K.L.; ESTRADA, Y. O.; GENOVA, R. C.; GIRMA, B.; KISSEL, E. S.; LEVY, A. N.; MACCRACKEN, S.; MASTRANDEREA, P. S.; WHITE, L. L. (Ed.). **Climate change 2014: impacts, adaptation and vulnerability: part A: global and sectoral aspects**. Cambridge: Cambridge University Press, 2014. p. 271-359.

SHANG, W.; HUANG, H.; ZHU, H.; LIN, Y.; QU, Y.; WANG, Z. A novel feature selection algorithm for text categorization. **Expert Systems with Applications**, v.33, n.1, p.1-5, 2007.

SHIMABUKURO, Y. E.; ARAI, E.; DUARTE, V.; JORGE, A.; SANTOS, E. G.; GASPARINI, K. A. C.; DUTRA, A. C. Monitoring deforestation and forest degradation using multi-temporal fraction images derived from Landsat sensor data in the Brazilian Amazon. **International Journal of Remote Sensing**, 2019. DOI: 10.1080/01431161.2019.1579943.

SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fractions images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v.29, n.1, p.16-20, 1991.

SHIMABUKURO, Y.E.; DUARTE, V.; ARAI, E.; FREITAS, R.M.; MARTINI, P.R.; LIMA, A. Monitoring land cover in Acre State, western Brazilian Amazonia, using multitemporal remote sensing data. **International Journal of Image and Data Fusion**, v.1, n.4, p.325-335, 2010.

SHIMABUKURO, Y.E.; ARAI, E.; ANDERSON, L. O.; ARAGÃO, L. E. O. C.; V. DUARTE. Mapping degraded forest areas caused by fires during the year 2010 in Mato Grosso state, Brazilian Legal Amazon using Landsat-5 TM fraction images. **Revista Brasileira de Cartografia**, v.69, n.1, p.23-32, 2017.

SHIMABUKURO, Y.E.; ARAI, E.; DUARTE, V.; JORGE, A.; SANTOS, E.G.D.; GASPARINI, K.A.C.; DUTRA, A.C. Monitoring deforestation and forest degradation using multi-temporal fraction images derived from Landsat sensor data in the Brazilian Amazon. **International Journal of Remote Sensing**, p.1-22, 2019.

SHIMABUKURO, Y.E.; DUARTE, V.; ARAI, E.; FREITAS, R. M.; LIMA, A.; VALERIANO, D. M.; BROWN, I. F.; MALDONADO, M. L. R. Fraction images derived from Terra MODIS data for mapping burnt areas in Brazilian Amazonia. **International Journal of Remote Sensing**, v.30, p.1537-1546, 2009. DOI:10.1080/01431160802509058.

SHIMABUKURO, Y.E; PONZONI, F.J. **Mistura espectral: modelo linear e aplicações**. São Paulo: Oficina de Textos, 2017. ISBN 978-85-7975-270-4.

SILVA JUNIOR, C.A.; FRANK, T.; RODRIGUES, T. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental Agriambi**, v.18, p.44-53, 2014.

SILVA, A. C. D. C.; PRATA, A. P. D. N.; SOUTO, L. S.; MELLO, A. A. D. Aspectos de ecologia de paisagem e ameaças à biodiversidade em uma unidade de conservação na Caatinga, em Sergipe. **Revista Árvore**, Viçosa, v. 37, n. 3, p. 479-490, 2013.

SILVA, J.M.C.; LEAL, I.R.; TABARELLI, M. **Caatinga: the largest tropical dry forest region in South America**. Berlin: Springer, 2018.

SILVA, L. R.; SANO, E. E. Análise das imagens do satélite RapidEye para discriminação da cobertura vegetal do bioma Cerrado. **Revista Brasileira de Cartografia**, v. 68, n. 7, p1267-1283, 2016.

SINGH, K. P.; KUSHWAHA, C. P. Emerging paradigms of tree phenology in dry tropics. **Current Science**, v.89, n.6, p.964-975, 2005.

SONNENSCHN, R.; KUEMMERLE, T.; UDELHOVEN, T.; STELLMES, M.; HOSTERT, P. Differences in Landsat-based trend analyses in drylands due to the choice of vegetation estimate. **Remote Sensing of Environment**, v.115, p.1408–1420, 2011.

SOUZA JUNIOR, C.A.; AZEVEDO, T. **Algorithm theoretical base document: results**. 2017. Disponível em: https://storage.googleapis.com/mapbiomas/base-de-dados/metodologia/colecao-2_3/ATBD-MapBiomias-Geral-2018-01-07.pdf. Acesso em: 26 jan. 2018.

SOUZA, C. M.; ROBERTS, D. A.; COCHRANE, M. A. Combining spectral and spatial information to map canopy damage from selective logging and forest fires. **Remote Sensing of Environment**, v.98, n.2/3, p.329-343, 2005. DOI: 10.1016/j.rse.2005.07.013.

SOUZA, C. M.; SIQUEIRA, J. V.; SALES, M. H.; FONSECA, A. V.; RIBEIRO, J. G.; NUMATA, I.; COCHRANE, M. A.; BARBER, C. P.; ROBERTS, D. A.; BARLOW, J. Ten-year Landsat classification of deforestation and forest degradation in the Brazilian Amazon. **Remote Sensing**, v.5, n.11, p.5493-5513, 2013. DOI: 10.3390/rs5115493.

SOUZA, C.; FIRESTONE, L.; SILVA, L. M.; ROBERTS, D. Mapping forest degradation in the eastern Amazon from SPOT 4 through spectral mixture models. **Remote Sensing of Environment**, v.87, n.4, p.494–506, 2003. DOI:10.1016/j.rse.2002.08.002.

THORP, K.R.; FRENCH, A.N.; RANGO, A. Effect of image spatial and spectral characteristics on mapping semi-arid rangeland vegetation using multiple endmember spectral mixture analysis (MESMA). **Remote Sensing of Environment**, v.132, p.120-130, 2013.

TOMASELLA, J.; VIEIRA, R.M.S.P.; BARBOSA, A.A.; RODRIGUEZ, D.A.; DE OLIVEIRA SANTANA, M.; SESTINI, M.F. Desertification trends in the Northeast of Brazil over the period 2000–2016. **International Journal of Applied Earth Observation and Geoinformation**, v.73, p.197-206, 2018.

UNITED NATIONS – UN. **Sustainable development goals: 15**. 2017. Disponível em: <https://sustainabledevelopment.un.org/sdg15>.

UNITED STATES GEOLOGICAL SURVEY - USGS. **MODIS reprojection tool V4.1**. 2011. Disponível em: <http://lpdaac.usgs.gov/lpdaac/tools/>.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 8 (L8): data users handbook**. Reston: USGS, June, 2015.

UNITED STATES GEOLOGICAL SURVEY – USGS. **Global visualization**. Disponível em: <http://landsat.usgs.gov>. Acesso em: 20 jan. 2018.

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

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

WALKER, J. J.; DE BEURS, K. M.; WYNNE, R. H.; GAO, F. Evaluation of Landsat and MODIS data fusion products for analysis of dryland forest phenology. **Remote Sensing of Environment**, v. 117, p. 381-393, 2012.

WANG, C.; TANG, Y.; CHEN, J. Plant phenological synchrony increases under rapid within-spring warming. **Nature Scientific Reports**, v.6, p.25460, 2016.

WULDER, M.A.; WHITE, J.C.; GOWARD, S.N.; MASEK, J.G.; IRONS, J.R.; HEROLD, M.; COHEN, W.B.; LOVELAND, T.R.; WOODCOCK, C.E. Landsat continuity: issues and opportunities for land cover monitoring. **Remote Sensing of Environment**, v. 112, n. 3, p. 955-969, 2008.

YANG, J.; WEISBERG, P.J.; BRISTOW, N.A. Landsat remote sensing approaches for monitoring long-term tree cover dynamics in semi-arid woodlands: comparison of vegetation indices and spectral mixture analysis. **Remote Sensing of Environment**, v.119, p.62-71, 2012.

ZHU, Z.; WOODCOCK, C.E. Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: an algorithm designed specifically for monitoring land cover change. **Remote Sensing of Environment**, v.152, p.217-234, 2014.