



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

sid.inpe.br/mtc-m21c/2018/04.29.22.45-TDI

**DETECÇÃO DE ÁREAS QUEIMADAS NA AMAZÔNIA
UTILIZANDO IMAGENS DE MÉDIA RESOLUÇÃO
ESPACIAL, TÉCNICAS DE GEOBIA E MINERAÇÃO
DE DADOS**

Thales Vaz Penha

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Leila Maria Garcia
Fonseca, e Thales Sehn Körting,
aprovada em 08 de maio de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3R2LBLB>>

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (COCST)

Dr. André de Castro Milone - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

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

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

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

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

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 Duca Barbedo - Serviço de Informação e Documentação (SESID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

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



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

sid.inpe.br/mtc-m21c/2018/04.29.22.45-TDI

**DETECÇÃO DE ÁREAS QUEIMADAS NA AMAZÔNIA
UTILIZANDO IMAGENS DE MÉDIA RESOLUÇÃO
ESPACIAL, TÉCNICAS DE GEOBIA E MINERAÇÃO
DE DADOS**

Thales Vaz Penha

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Leila Maria Garcia
Fonseca, e Thales Sehn Körting,
aprovada em 08 de maio de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3R2LBLB>>

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Penha, Thales Vaz.

P376d Detecção de áreas queimadas na Amazônia utilizando imagens de média resolução espacial, técnicas de GEOBIA e mineração de dados / Thales Vaz Penha. – São José dos Campos : INPE, 2018. xxvi + 139 p. ; (sid.inpe.br/mtc-m21c/2018/04.29.22.45-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

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

1. Mapeamento de áreas queimadas. 2. índices espectrais. 3. Análise baseada em objetos. 4. Florestas Tropicais. 5. Mineração de dados. I.Título.

CDU 528.8:630*43



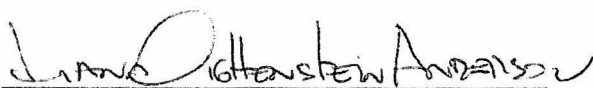
Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

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

Aluno (a): *Thales Vaz Penha*
Título: "DETECÇÃO DE ÁREAS QUEIMADAS NA AMAZÔNIA UTILIZANDO IMAGENS DE MÉDIA RESOLUÇÃO ESPACIAL, GEOBIA E MINERAÇÃO DE DADOS".

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

Dra. Liana Oigheinstein Anderson



Presidente / CEMADEN / São José dos Campos - SP

Participação por Vídeo - Conferência

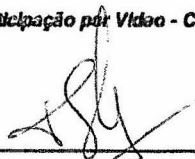
Dra. Leila Maria Garcia Fonseca



Orientador(a) / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Dr. Thales Sehn Körting



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

Participação por Vídeo - Conferência

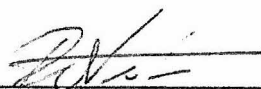
Dr. Fabiano Morelli



Membro da Banca / INPE / São José dos Campos - SP

Participação por Vídeo - Conferência

Dr. Raul Queiroz Feitosa



Convidado(a) / PUC-Rio/DEE / Rio de Janeiro - RJ

Participação por Vídeo - Conferência

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 08 de maio de 2018

“Desde o começo eu não disse, seu moço

Ele disse que chegava lá

Olha aí! Olha aí!

Olha aí!

Ai, o meu guri, olha aí!

Olha aí!

É o meu guri”.

Chico Buarque de Holanda

Aos meus avós, pais e amigos. Essa conquista é nossa.

AGRADECIMENTOS

Aos meus orientadores, Dra. Leila Fonseca e Dr. Thales Körting, pela oportunidade, por acreditarem no meu potencial, pelas trocas de conhecimentos, parceria e suporte.

Aos pesquisadores, Dra. Liana Anderson, Dr. Fabiano Morelli e Dr. Raul Feitosa por aceitarem o convite para participação da banca e por todas as contribuições à dissertação.

Ao INPE e todos os pesquisadores, colegas e funcionários, por oferecer excelente qualidade de ensino e infraestrutura, diálogos, aprendizagens, parcerias, trocas de experiências e convivência em um ambiente excepcional que permitiram meu crescimento profissional e pessoal.

A Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES), pelo apoio financeiro.

Aos meus amigos inpeanos, em especial a turma 2°C, por toda união, suporte emocional, diversão, companheirismo, trocas, viagens, festas, bolos e grandes momentos. Em especial, aos grandes amigos inpeanos para toda uma vida: Raquel, Renata, Celso, Alindomar, Mikhaela, Jéssica, Téhrrie, Maria, Clarissa, Nati e Anderson.

À minha família, por ser o alicerce de tudo. Em especial, aos meus pais (Edmar e Lúcia) e irmão (Cássio), pelos incentivos, união e apoio incondicional. Aos meus padrinhos (Sérgio e Carlos), madrinhas (Sílvia e Vilma) e primas (Dani e Claudia) por serem exemplos de determinação e conquistas.

À Elena, por ser a fã número 1, pelo companheirismo, pela admiração mútua e por escolhermos caminhar juntos. As minhas grandes amigas de longa data: Luara, Tais e Iane por todos os incentivos e conversas. Aos amigões da vida, da Cidade, e tantos outros que tornaram essa jornada possível e especial.

RESUMO

O mapeamento refinado de áreas queimadas na Amazônia brasileira ainda é um desafio. A principal dificuldade na detecção de áreas queimadas para grandes extensões territoriais é devido à cobertura de nuvens, presença de sombras e a detecção de incêndios florestais. A integração de imagens de média resolução espacial (~30m) pode fornecer uma maior disponibilidade de imagens orbitais adequadas, diminuindo as incertezas associadas aos dados de resolução espacial mais baixa (>250m), os quais subestimam/superestimam áreas queimadas e dificultam a detecção de pequenas manchas de áreas queimadas. Neste estudo, uma metodologia baseada em índices espectrais, Análise de Imagem Baseada em Objetos Geográficos (GEOBIA), imagens de média resolução espacial e Mineração de Dados foi proposta para refinar o mapeamento de áreas queimadas na região amazônica, dividido em duas fases de experimentos. Na primeira, nove índices espectrais foram avaliados em duas cenas dos sensores Landsat-8 OLI e Sentinel-2 MSI, em duas áreas de estudo. Para isso, modelos de detecção de áreas queimadas com base em técnicas de GEOBIA e índices espectrais foram construídos. Na segunda, modelos de detecção baseados em técnicas de GEOBIA e Mineração de Dados para três áreas de estudo, utilizando imagens Landsat-8 OLI, Sentinel-2 MSI e CBERS-4 MUX, foram desenvolvidos. Esta fase teve como objetivo identificar os atributos descritores mais relevantes de áreas queimadas. Os resultados mostraram que o índice Burned Area Index (BAI) é o mais adequado para este mapeamento ($M > 1,5$). Além disso, índices espectrais e bandas espectrais cujas faixas de espectro eletromagnético contemplam as bandas do infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR) são as mais indicadas para detecção de áreas queimadas. Com efeito, os modelos de detecção de áreas queimadas baseado em GEOBIA permitiram detectar mais de 80% das áreas queimadas pequenas ($< 0,1 \text{ km}^2$) com altos valores de Coeficiente Dice (DC) (cerca de 0,70) e baixos erros de omissão e comissão, 22% e 32%, respectivamente. Ademais, a aplicação do algoritmo do CSF e da árvore de decisão (J48) foi adequada (apresentando DC médio de 0,80, erros de omissão e comissão de 17% e 22%, respectivamente), permitindo uma interpretação robusta da seleção automática de atributos para detectar e caracterizar as áreas queimadas. Os modelos criados com base no caminho majoritário apresentaram em média 10% do tamanho das árvores de decisão originais, e foram capazes de detectar aproximadamente 42% das áreas queimadas. Os resultados indicam os atributos mais importantes para a construção de novos modelos, sendo os melhores atributos descritores baseados em pixel, objetos e textura derivados do BAI e NIR. Finalmente, este estudo recomenda o uso de imagens dos sensores OLI, MSI e MUX para a detecção e monitoramento de áreas queimadas, uma vez que contribuem para a maior disponibilidade de imagens adequadas sem cobertura de nuvens. Como trabalhos futuros sugere-se a aplicação dos modelos propostos para detectar áreas queimadas em outras localidades da Amazônia, bem como o uso de outras imagens de média resolução espacial.

Palavras-chave: Mapeamento de áreas queimadas. Índices Espectrais. Análise baseada em objetos. Florestas tropicais. Multi-sensores ópticos. Mineração de Dados. Landsat-8. Sentinel-2. CBERS-4.

BURNED AREAS DETECTION IN AMAZONIA USING MEDIUM SPATIAL RESOLUTION IMAGES, GEOBIA AND DATA MINING TECHNIQUES

ABSTRACT

Refined burned areas (BA) mapping in the Brazilian Amazon is still a challenge. The main difficulty in BA detection for large areas is due to the occurrence of cloud coverage, the presence of shadows and forest fires detection. The integration of different data sources of medium spatial resolution satellite images can provide a wider range of suitable orbital images (without cloud coverage) and decrease the uncertainties associated to coarse spatial resolution data, which might underestimate or overestimate BA and difficult the detection of small BA patches. In this study, a methodology based on spectral indices, Geographic Object-Based Image Analysis (GEOBIA), medium resolution images and data mining has been used to improve the mapping of BA in the Amazon region, divided in two experimental phases. The first evaluates the performance of nine spectral indices for BA detection in two scenes from Landsat-8 OLI and Sentinel-2 MSI, using two different study areas. BA detection models based on GEOBIA and spectral indices were developed in order to do so. For the second phase, classification models based on GEOBIA techniques and data mining was developed for three study areas, including Landsat-8 OLI, Sentinel-2 MSI and CBERS-4 MUX imagery, seeking the identification of the most relevant descriptor attributes of BA. The results showed that Burned Area Index (BAI) is the most suitable index for BA mapping ($M \text{ index} > 1.5$). Furthermore, spectral indices and spectral bands whose electromagnetic spectrum ranges contemplate the NIR and SWIR bands are the most indicated for BA detection. On top of that, the BA detection model based on GEOBIA allowed the detection of more than 80% of the small BA ($< 0,1 \text{ km}^2$) presenting high Dice Coefficient (DC) values (about 0.70) and low omission and commission errors of 22% and 32%, respectively. Besides, the usage of CSF algorithm and decision tree (J48) methods were adequate (DC about 0.80, omission and commission of 17% and 22%, respectively), allowing a robust interpretation of the automatic selection of attributes to detect and characterize the BA. In addition, the BA detection models based on the major path presented average size of 10% of the original decision trees and were able to detect around 42% of BA. The results show which are the most important attributes when constructing new models, the best being the ones based on pixel, objects and textural type derived from BAI and NIR band. Finally, this study recommends the use of OLI, MSI and MUX sensors for BA detection and monitoring, since they contribute to the availability of suitable images without cloud coverage. Further studies are encouraged to apply the proposed model of BA detection to other Amazon sites and a wider use of medium spatial resolution images.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Diferentes áreas queimadas encontradas na Amazônia.	7
Figura 2.2 - Histórico mensal de focos de calor (1999-2016) para a Amazônia Legal, segundo os dados de referência dos sensores NOAA-AVHRR Noite/AQUA-MODIS UMD Tarde.	8
Figura 2.3 - Comparativo de classificação de áreas queimadas em uma região da Amazônia, destacando as diferenças de exatidão dos mapeamentos com diferentes fontes de dados de SR.....	14
Figura 2.4 - Processo da descoberta de conhecimento em bases de dados (KDD).	23
Figura 3.1 - Fluxograma das etapas da pesquisa.	27
Figura 3.2 - Desenho amostral da pesquisa.	28
Figura 3.3 - Localização das áreas de estudo (APs).	30
Figura 3.4 - Localização e recorte espacial das APs.	32
Figura 3.5 - Distribuição espacial das áreas queimadas de referência nas APs.	35
Figura 3.6 - Correspondência da RSRF dos sensores Landsat-8 OLI (L8 OLI) e Sentinel-2 MSI (S2 MSI).	37
Figura 3.7 - Perfil espectral de uma área queimada nos sensores Landsat-8 OLI (L8 OLI) e Sentinel-2 MSI (S2 MSI).....	39
Figura 3.8 - Modelo de avaliação de exatidão das áreas queimadas.	54
Figura 4.1 - <i>Boxplots</i> dos índices espectrais normalizados para AP1: (A) <i>Boxplots</i> para imagem Landsat-8 OLI; (B) <i>Boxplots</i> para imagem Sentinel-2 MSI.....	58
Figura 4.2 - <i>Boxplots</i> dos índices espectrais normalizados para AP2: (A) <i>Boxplots</i> para imagem Landsat-8 OLI; (B) <i>Boxplots</i> para imagem Sentinel-2 MSI.....	59
Figura 4.3 - Resultado do Índice de separabilidade M para todos os índices espectrais na AP1.....	63
Figura 4.4 - Resultado do Índice de separabilidade M para todos os índices espectrais na AP2.....	63
Figura 4.5 - Histogramas do índice espectral BAI para AP1 e imagem Landsat-8 OLI de acordo com as três limiares testados.	65

Figura 4.6 - Modelo de filtragem empírica para refinar a detecção de áreas queimadas usando o índice BAI para as áreas de estudo AP1 (A) e AP2 (B).	68
Figura 4.7 - Mapa refinado de áreas queimadas após a etapa de filtragem para AP1: (A) imagem Landsat-8 OLI; (B) Imagem do Sentinel-2.	70
Figura 4.8 - Mapa refinado de áreas queimadas após a etapa de filtragem para AP2: (A) imagem Landsat-8 OLI; (B) Imagem do Sentinel-2.	71
Figura 4.9 - Frequência dos tipos de atributos por banda, selecionados pelo algoritmo CSF.....	74
Figura 4.10 - Número de ocorrência dos principais atributos descritores segundo os modelos de detecção de áreas queimadas pelo caminho majoritário.	84
Tabela B.1 - Matrizes de confusão para o teste de limiares BAI na AP1.	108
Tabela B.2 - Matrizes de confusão para o teste de limiares BAI na AP2.	109
Tabela B.3 - Matrizes de confusão para os modelos refinados de detecção de áreas queimadas.....	109
Figura C.1 - A árvore de decisão gerada pelo algoritmo J48 para AP1 - Landsat-8 OLI.	112
Figura C.1- Continuação.	115
Figura C.2 - Árvore de decisão gerada pelo algoritmo J48 para AP1 – Sentinel-2 MSI.	116
Figura C.2 - Continuação.	118
Figura C.3 - Árvore de decisão gerada pelo algoritmo J48 para AP2 – Landsat-8 OLI.	119
Figura C.3 - Continuação.	123
Figura C.4: Árvore de decisão gerada pelo algoritmo J48 para AP2 – Sentinel-2 MSI.	124
Figura C.4 - Continuação.	126
Figura C.5 - Árvore de decisão gerada pelo algoritmo J48 para AP3 – Landsat-8 OLI.	127
Figura C.6 - Árvore de decisão gerada pelo algoritmo J48 para AP3 – CBERS-4 MUX.	133

- Figura D.1 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP1: (A) Landsat-8 OLI; (B) Sentinel-2 MSI. 138
- Figura D.2 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP2: (A) Landsat-8 OLI; (B) Sentinel-2 MSI. 139
- Figura D.3 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP3: (A) Landsat-8 OLI; (B) CBERS-4 MUX..... 139

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Sensores de média resolução espacial com potencial para detecção de áreas queimadas na Amazônia.....	12
Tabela 2.2 - Iniciativa de estudos recentes de detecção de área queimada em diferentes escalas, dados de SR, localidades e métodos.	16
Tabela 2.3 - Principais índices espectrais para detecção de áreas queimadas e vegetação.	19
Tabela 2.4 - Estudos recentes de mapeamento de áreas queimadas usando índices espectrais.	20
Tabela 3.1 - Descrição das características das áreas pilotos (APs).	31
Tabela 3.2 - Dados de sensoriamento remoto adquiridos.....	34
Tabela 3.3 - Bandas espectrais das imagens Landsat-8 OLI e Sentinel-2 MSI selecionadas.....	37
Tabela 3.4 - Bandas espectrais selecionadas das imagens Landsat-8 OLI e CBERS-4 MUX.....	38
Tabela 3.5 - Índices espectrais usados neste estudo.	40
Tabela 3.6 - Dados de entrada de cada Área Piloto para a segunda fase da metodologia.	44
Tabela 3.7 - Valores ótimos estimados para os parâmetros de segmentação em cada área de estudo e tipo de imagem.	46
Tabela 3.8 - Definição das tipologias de classes presentes nas imagens.....	48
Tabela 3.9 - Alguns atributos espectrais e espaciais da abordagem baseada em objetos.	50
Tabela 3.10 - Modelo de matriz de confusão.	55
Tabela 4.1 - Índice de separabilidade M para os índices espectrais e classificação dos melhores índices em cada AP.....	62
Tabela 4.2 - Erros de Omissão (Eo), Erros de Comissão (Ec), Coeficiente Dice (DC) e o Erro Relativo (RelB) calculados para os testes de limiares.	67
Tabela 4.3 - Eo, Ec, DC e RelB para os mapeamento refinado de áreas queimadas.	69

Tabela 4.4 - Porcentagem dos polígonos de áreas queimadas em cada AP e sensores em relação ao seu tamanho, definido em quatro intervalos.	72
Tabela 4.5 - Produto de fogo ativo NOAA VIIRS-NPP (375m) acumulado um mês antes da aquisição das imagens.	73
Tabela 4.6 - Resumo do processo de seleção de atributos e mineração de dados.	74
Tabela 4.7 - Atributos selecionados pelo algoritmo CSF, para cada área de estudo.	75
Tabela 4.7 – Continuação.	76
Tabela 4.7 – Conclusão.	77
Tabela 4.8 - Eo, Ec, DC e RelB para os mapeamento de áreas queimadas refinados.	78
Tabela 4.9 - Modelos de classificação pelo caminho majoritário [n° de amostras/n° total de amostras].....	79
Tabela 4.9 – Continuação.	80
Tabela 4.10 - Resumo dos modelos de classificação pelo caminho majoritário.	81
Tabela 4.11 - Principais atributos identificados para o modelo de detecção de áreas queimadas pelo caminho majoritário.	82
Tabela 4.11 – Continuação.	83
Tabela A.1 - Dinâmica progressiva para determinação empírica dos parâmetros de segmentação.	103
Tabela A.1 – Continuação.	104
Tabela A.2 - Lógica progressiva para determinação empírica dos parâmetros de segmentação.	105
Tabela A.2 – Continuação.	106
Tabela C.1 - Nomes e siglas dos atributos.....	110
Tabela C.1 - Continuação.	111

LISTA DE SIGLAS E ABREVIATURAS

INPE	Instituto Nacional de Pesquisas Espaciais
IBGE	Instituto Brasileiro de Geografia e Estatística
SR	Sensoriamento Remoto
AP	Área Piloto
OLI	<i>Operational Land Imager</i>
MSI	<i>Multi Spectral Instrument</i>
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
MUX	<i>Câmera Multiespectral Regular</i>
PDI	Processamento Digital de Imagens
DGI	Divisão de Geração de Imagens
MLME	Modelo Linear de Mistura Espectral
GEOBIA	<i>Geographic Object-Based Image Analysis</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
VIIRS	<i>Visible Infrared Imaging Radiometer Suite</i>
NPP	<i>Suomi National Polar-orbiting Partnership (NPP) satellite</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
ESA	<i>European Space Agency</i>
USGS	<i>United State Geological Survey</i>
WRS	<i>Worldwide Reference System</i>
TOA	<i>Top-Of-Atmosphere</i>
BOA	<i>Bottom-Of-Atmosphere</i>
SNAP	<i>Sentinel Application Platform</i>
EQM	Erros Quadráticos Médios
RSRF	<i>Relative Spectral Response Function</i>
NIR	<i>Near Infrared</i>
SWIR	<i>Short Wave Infrared</i>
TIR	<i>Thermal Infrared</i>

BAI	<i>Burned Area Index</i>
MIRBI	<i>Mid-Infrared Burn Index</i>
NBR	<i>Normalized Burn Ratio</i>
CSI	<i>Char Soil Index</i>
NBRT	<i>Normalized Burn Ratio Thermal</i>
SR	<i>Simple Ratio</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
EVI	<i>Enhanced Vegetation Index</i>
BAIM	<i>Burned Area Index Modified</i>
VI6T	<i>Vegetation Index Number 6 Thermal</i>
DM	<i>Data Mining</i>
KDD	<i>Knowledge Discovery in Databases</i>
ANN	<i>Artificial Neural Network</i>
SVM	<i>Support Vector Machine</i>
SOM	<i>Self Organizing Maps</i>
DC	<i>Dice Coefficient</i>
RelB	<i>Relative Bias</i>
Eo	Erro de omissão
Ec	Erro de comissão
RGB	<i>Red, Green, Blue composition</i>
Fmask	<i>Function of Mask</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>
CSF	<i>Correlation Feature Selection</i>
J48	Algoritmo de árvore de decisão
CV	Coeficiente de Variação
GLCM	<i>Grey Level Co-Occurrence Matrix</i>

LISTA DE SÍMBOLOS

σ	Desvio Padrão
μ	Média
M	Índice de Separabilidade M

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1. Objetivo.....	4
1.2. Objetivos Específicos.....	4
2 REFERENCIAL TEÓRICO	5
2.1. Queimadas na Amazônia.....	5
2.2. Sensoriamento Remoto Aplicado ao Estudo de Queimadas	8
2.3. Imagens de Média Resolução Espacial	11
2.4. Classificação de Áreas Queimadas	13
2.5. Métodos de Processamento Digital de Imagens	17
2.5.1. Índices Espectrais.....	17
2.5.2. GEOBIA.....	21
2.5.3. Mineração de Dados.....	22
3 METODOLOGIA	27
3.1. Desenho Amostral.....	28
3.2. Áreas de Estudo.....	28
3.3. Primeira Fase.....	33
3.3.1. Aquisição dos dados.....	33
3.3.2. Dados de Referência	34
3.3.3. Pré-processamento e Compatibilização dos Dados.....	36
3.3.4. Aplicação dos Índices Espectrais	39
3.3.5. Análise Estatística	40
3.3.6. Testes de Limiares.....	42
3.3.7. Modelo Refinado de Detecção de Áreas Queimadas	42
3.4. Segunda Fase.....	43
3.4.1. Dados de Entrada	43
3.4.2. Pré-processamento dos Dados de Entrada	44
3.4.3. Segmentação	45
3.4.4. Tipologia e Definição das Classes	47

3.4.5. Extração de Atributos.....	49
3.4.6. Seleção de Atributos	51
3.4.7. Mineração de Dados.....	51
3.4.8. Avaliação da Exatidão dos Produtos de Áreas Queimadas.....	53
4 RESULTADOS E DISCUSSÃO	57
4.1. Avaliação dos Índices Espectrais	57
4.2. Ranking dos Índices Espectrais.....	60
4.3. Resultados dos Testes de Limiares	64
4.4. Resultados do Modelo de Detecção de Áreas Queimadas	67
4.5. Resultados da Seleção de Atributos e Mineração de Dados	73
4.6. Modelos de Detecção de Áreas Queimadas por Árvore de Decisão.....	78
4.7. Atributos Descritores de Áreas Queimadas	81
4.8. Imagens de Média Resolução Espacial para Detecção de Áreas Queimadas	84
5 CONCLUSÕES	87
REFERÊNCIAS BIBLIOGRÁFICAS	91
APÊNDICE A - DINÂMICA PROGRESSIVA DE TESTES DE VALORES DOS PARÂMETROS DE SEGMENTAÇÃO	103
APÊNDICE B - MATRIZES DE CONFUSÃO DAS ETAPAS DE TESTE DE LIMIARES E DO MODELO REFINADO DE DETECÇÃO DE ÁREAS QUEIMADAS	108
APÊNDICE C - ÁRVORES DE DECISÃO GERADAS	110
APÊNDICE D - MATRIZES DE CONFUSÃO DAS ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO J48	138

1 INTRODUÇÃO

O bioma Amazônia, tratada a partir deste ponto apenas como Amazônia, abrange uma área de cerca de 4,2 milhões de km² ou 49,29% da extensão territorial do país (IBGE, 2004) e engloba parte de nove estados brasileiros: Amazonas, Pará, Acre, Amapá, Roraima, Rondônia, Tocantins, Mato Grosso e Maranhão. Entre os diferentes desafios enfrentados pela região Amazônica, destacam-se aqueles relacionados às emissões de grandes quantidades de gases de efeito estufa (FEARNSIDE, 2005; ARAGÃO et al., 2014), tais como as queimadas relacionadas ao desmatamento (ARAGÃO; SHIMABUKURO, 2010; FANIN et al., 2015), ao manejo da terra (LIMA et al., 2012; ANDERSON et al., 2015), aos incêndios florestais e as queimadas de sub-bosque (ALENCAR et al., 2006; MORTON et al., 2011), cujos diferentes propósitos visam gerenciar e transformar o uso e cobertura da terra, especialmente em ecossistemas tropicais e subtropicais (van der WERF et al., 2010).

O uso do fogo no manejo e gestão da terra, associado às secas mais intensas e frequentes, tem contribuído para o aumento de queimadas na Amazônia (ARAGÃO et al., 2007). Nesse sentido, estimativas realizadas pelo Programa de Monitoramento de Queimadas do Instituto Nacional de Pesquisas Espaciais (INPE) apontam que entre 2005 e 2016 cerca de 1,4 milhão de km² (33,33% da área total) foram queimados na Amazônia (INPE, 2017).

A ocorrência de queimadas e incêndios florestais na Amazônia gera uma grande quantidade de impactos socioeconômicos e ecológicos (ANDERSON et al., 2015), como a redução da biomassa florestal devido à mortalidade das árvores grandes (BARLOW et al., 2003), a mudança na composição das espécies de árvores (BARLOW; PERES, 2008), o empobrecimento do solo, perda de biodiversidade e perdas econômicas para a sociedade (PIROMAL et al., 2008; PIVELLO, 2011), bem como efeitos indiretos, como a piora da qualidade do ar, que afeta a saúde humana (SMITH et al., 2014). Desta forma, a importância dos incêndios florestais como fenômeno natural ou induzido pelo homem ganhou reconhecimento não só em escala local, mas também em perspectivas regional e global (GITAS et al., 2004; ARAGÃO et al., 2018).

A detecção de mudanças nos ecossistemas terrestres, após um incêndio, é essencial em termos de avaliação da área queimada e análises dos impactos sobre a biomassa e biodiversidade, bem como o monitoramento e a recuperação da área afetada pós-fogo (KATAGIS et al., 2014). Nesse sentido, uma das variáveis cruciais para quantificar a extensão da queima de biomassa em escala global é o tamanho da área queimada. Para isso, os dados de Sensoriamento Remoto (SR) têm sido usados, uma vez que permitem a espacialização e o monitoramento temporal desses eventos (ANDERSON et al., 2005).

As melhorias significativas dos sensores orbitais de SR têm resultado em um número crescente de produtos derivados que detectam tanto o fogo ativo quanto as áreas queimadas (MOUILLOT et al. 2014). No Brasil, estudos de detecção de áreas queimadas foram desenvolvidos principalmente a Amazônia (SHIMABUKURO et al., 2009; LIMA et al., 2012; da SILVA CARDOZO et al., 2014; ANDERSON et al., 2017) e Cerrado (FRANÇA; SETZER, 2001; LIBONATI et al., 2015) com o objetivo de gerar produtos mais precisos para apoiar o monitoramento dessas áreas e melhorar as estimativas das emissões de gases do efeito estufa.

A detecção de incêndios florestais e o mapeamento de áreas queimadas têm sido comumente realizados com dados de SR com resolução espacial mais grosseira (> 250 m), que possuem alta resolução temporal e permitem o monitoramento quase em tempo real, cobrindo assim todo o período da estação mais seca (época das queimadas) em grandes áreas (SHIMABUKURO et al., 2015). No entanto, o monitoramento a partir de destes tipos de dados pode distorcer a estimativa geral e a distribuição espacial das áreas queimadas (LARIS, 2005; MIETTINEN et al., 2013; SHIMABUKURO et al., 2015), bem como limitar a capacidade de detectar pequenas manchas de queimadas (LARIS, 2005). Desta forma, as incertezas associadas às abordagens de resolução espacial mais fina provavelmente serão menores do que as abordagens de baixa resolução espacial (ANDERSON et al., 2015). No entanto, esta abordagem pode estar sujeita a uma maior incerteza se os resultados precisarem ser extrapolados para áreas maiores (van der WERF et al., 2010).

Uma das principais dificuldades na geração de produtos mais precisos de áreas queimadas deve-se à presença de nuvens, que apresentam uma resposta espectral semelhante às áreas queimadas, gerando assim erros de detecção/classificação e

tornando a disponibilidade de dados instável. Além disso, a ocorrência de incêndios em floresta e em sub-bosque dificulta a estimativa de áreas queimadas para grandes extensões territoriais devido às limitações metodológicas de detecção e características inerentes dos sensores imageadores, à configuração da paisagem e ao tamanho das manchas queimadas, assim como, a intensidade e duração do incêndio (MIETTINEN et al., 2013; ANDERSON et al., 2017).

Shimabukuro et al. (2015) sugerem a aplicação de imagens de satélite de média resolução espacial (variando de 10 a 50 metros, de acordo com EHLERS et al., 2002) para a avaliação das áreas queimadas, uma vez que apresentam maiores detalhes e permitem análises mais confiáveis e adequadas, relacionadas à extensão, distribuição e características de áreas queimadas. Latorre et al. (2007) propõem a integração de diferentes fontes de dados para aumentar a disponibilidade de imagens orbitais sem cobertura de nuvem para uma região de interesse. No entanto, a integração de dados com diferentes características espaciais, espectrais, temporais e angulares requer atenção no processamento para evitar distorções e geração de artefatos nas imagens (MOUSIVAND et al., 2015).

Além disso, inúmeros estudos de detecção de áreas queimadas obtiveram resultados promissores aplicando índices espectrais (VERAVERBEKE et al., 2011; LIBONATI et al., 2012; SCHEPERS et al., 2014; SILVA CARDOZO et al., 2014; BASTARRIKA et al., 2014; PEREIRA et al., 2016). No entanto, há uma lacuna de estudos desta natureza voltados para a região Amazônica.

As técnicas convencionais de mapeamento de áreas queimadas na Amazônia são baseadas na aplicação de Modelo Linear de Mistura Espectral (MLME), e em algoritmos de classificação não supervisionados, seguida pela etapa de edição manual que visa diminuir os erros de omissão e comissão para melhorar a exatidão dos mapas. Por outro lado, o uso da abordagem baseada em objetos geográficos (GEOBIA - do inglês *Geographic Object-Based Image Analysis*) pode contribuir no refinamento da detecção de áreas queimadas uma vez que propõe extrair e utilizar informações espectrais e espaciais de objetos da imagem, além de permitir a criação de modelos de classificação baseado no conhecimento do especialista. Neste caso, esta técnica permite explorar e selecionar atributos mais relevantes na detecção de áreas queimadas.

Outras técnicas que podem ser investigadas na detecção de áreas queimadas são as de mineração de dados, que consistem em encontrar correlações, padrões e tendências nos dados por meio de modelos matemáticos, estatísticos e algoritmos automáticos de reconhecimento de padrões (LAROSE; LAROSE, 2014). Desta forma, é possível extrair informações úteis a partir de grandes volumes de dados (FAYYAD et al., 1996).

Neste contexto, este trabalho propõe utilizar índices espectrais, técnicas de GEOBIA e mineração de dados em imagens de média resolução espacial para a detecção de áreas queimadas na Amazônia. Os procedimentos metodológicos para detecção de áreas queimadas na Amazônia foram divididos em duas fases: a avaliação de índices espectrais para a detecção de áreas queimadas em imagens Landsat-8 OLI e Sentinel-2 MSI, indicando os melhores índices espectrais e os melhores limiares para identificação de áreas queimadas; e posteriormente o desenvolvimento de um modelo de classificação baseado em técnicas de GEOBIA e mineração de dados em imagens de média resolução espacial (Landsat-8 OLI, Sentinel-2 MSI e CBERS-4 MUX), indicando os principais atributos que descrevem as áreas queimadas na Amazônia.

1.1. Objetivo

Desenvolver uma metodologia para detecção de áreas queimadas na Amazônia, utilizando imagens de média resolução espacial dos sensores OLI do Landsat-8, MSI do Sentinel-2 e MUX do CBERS-4, com base em índices espectrais, e em técnicas de GEOBIA e mineração de dados.

1.2. Objetivos Específicos

- I. Estabelecer quais índices espectrais e limiares contribuem para a identificação de áreas queimadas;
- II. Identificar os atributos descritores mais relevantes na detecção de áreas queimadas por meio das técnicas de GEOBIA e mineração de dados;
- III. Gerar e avaliar diferentes modelos de detecção de áreas queimadas em diferentes localidades e imagens da Amazônia;
- IV. Verificar o potencial do uso de imagens de média resolução espacial no mapeamento de áreas queimadas na Amazônia.

2 REFERENCIAL TEÓRICO

2.1. Queimadas na Amazônia

A maioria dos tipos de vegetação no Brasil está sujeita à incêndios, em maior ou menor grau, dependendo do tipo, quantidade e secura do combustível, da fonte de ignição e do tipo de uso associado ao fogo (PIVELLO, 2011). O fogo desempenha um papel essencial no funcionamento de ecossistemas, na diversidade de espécies, na estrutura da comunidade vegetal e no armazenamento de carbono (FEARNSIDE, 2005). No entanto, quando foge do seu propósito, o fogo não controlado se torna um problema, causando danos econômicos e ambientais imprevistos. O escape de fogo provoca incêndios que destroem colheitas, pastagens, madeira, infraestrutura e gado, às vezes levando a severas dificuldades econômicas para as populações locais (COCHRANE, 2003).

Na Amazônia, historicamente a queimada é a principal ferramenta para limpeza da terra e viabilização de atividades antrópicas, como a agricultura e a manutenção de pastagens. Realizada de forma controlada, esta prática rapidamente converte a biomassa de florestas recém-derrubadas em cinzas ricas em nutrientes que são utilizadas para a fertilização de plantações, para o manejo agrícola, para manter o crescimento da floresta sob controle, reduzir pragas e promover o crescimento de forragem para animais domésticos (COCHRANE, 2003; FEARNSIDE, 2005; PIVELLO, 2011).

A prática de queimadas embora tenha benefícios também possui custos. O uso não controlado do fogo contribui para o aumento da ocorrência de incêndios florestais que tornam os ambientes impactados mais frágeis e susceptíveis aos subsequentes impactos climáticos e antropogênicos, tais como a redução da quantidade de biomassa da floresta e dos estoques de carbono, além do consequente aumento das emissões de gases do efeito estufa (van der WERF et al., 2010; ARAGÃO et al., 2014). Além disso, o impacto dos incêndios florestais nos ecossistemas depende do regime de fogo local, que inclui uma série de características importantes, tais como a frequência, intensidade, sazonalidade, entre outros (ARAGÃO et al., 2008; HANTSON et al., 2016).


De acordo com Aragão et al. (2008), os principais tipos de incêndios que ocorrem na Amazônia são: (i) em áreas que foram desmatadas e queimadas no mesmo ano, (ii) em áreas que foram desmatadas em anos anteriores e queimadas posteriormente, e (iii)

incêndios em vegetação natural e outras áreas não florestais. Além destes, há ocorrência de incêndios florestais de sub-bosque que são incêndios superficiais que queimam serrapilheiras e detritos lenhosos grosseiros em áreas de floresta intacta e degradada (MORTON et al., 2011). A Figura 2.1 ilustra os diferentes tipos de áreas queimadas encontradas na Amazônia.

Queimadas naturais ou acidentais na Amazônia são consideradas historicamente raras (BUSH et al., 2007). Desta forma, a maioria dos eventos de queimadas é resultante do uso deliberado do fogo para o manejo e manutenção das atividades antrópicas (COCHRANE, 1999; PIVELLO, 2011). A queimada quando não controlada, pode se tornar um incêndio florestal, provocando impactos diretos na vegetação, ocasionando a mortalidade de árvores (BARLOW et al., 2003) e, conseqüentemente, alterando a estrutura ecológica local (BARLOW; PERES, 2008; PIVELLO, 2011; VEENENDAAL et al., 2015). A dinâmica de uso da terra na região amazônica estimulada pelas atividades econômicas eleva a prática do fogo para conversão de áreas de florestas em agricultura e para criação e manutenção de áreas de pastagem (LIMA et al., 2012; ANDERSON et al., 2015).

As atividades antrópicas facilitam e aumentam a propagação do fogo em sistemas florestais por meio da exploração seletiva e pela criação e ampliação do efeito de borda, o que aumenta a inflamabilidade das florestas (ARAGÃO et al., 2008). Da mesma forma, o manejo do fogo em áreas de vegetação secundária e a rebrota em áreas desmatadas aumentam a vulnerabilidade das florestas à propagação de fogo, principalmente, durante períodos secos (ARAGÃO et al., 2008; ARAGÃO et al., 2014). (ARAGÃO et al., 2008; ARAGÃO et al., 2014).

Figura 2.1 - Diferentes áreas queimadas encontradas na Amazônia.




Legenda: (a) Floresta intacta no estado do Acre; (b) Floresta uma vez queimada no estado do Acre no ano de 2010; (c) Floresta duas vezes queimada no estado do Acre no ano de 2005 e 2010; (d) Fotografia aérea de uma queimada em pasto no dia 13 de outubro de 2005 no estado do Acre; (e) Área de pastagem queimada em 2016 no estado do Mato Grosso.

Fonte: Aragão et al. (2016) [Figuras 2.1a, 2.1b, 2.1c], Pantoja e Brown (2007) [Figura 2.1d], Neves (2017) [Figura 2.1e].

Na maior parte da região Amazônica, as queimadas tendem a se intensificar durante os meses de julho, agosto e setembro (Figura 2.2). Este período corresponde à estação seca com chuvas mensais abaixo de 100 mm, principalmente, nas partes sul e leste da Amazônia. De forma geral as queimadas se concentram ao longo do arco de desmatamento, onde a atividade humana é intensa. Isso demonstra claramente que existe a necessidade de ignição antrópica para ocorrência de queimadas, mesmo durante secas extremas na Amazônia (ARAGÃO et al., 2007; ARAGÃO et al., 2013).

Figura 2.2 - Histórico mensal de focos de calor (1999-2016) para a Amazônia Legal, segundo os dados de referência dos sensores NOAA-AVHRR Noite/AQUA-MODIS UMD Tarde.



Legenda: média e barra de erro.

Fonte: INPE (2016).

2.2. Sensoriamento Remoto Aplicado ao Estudo de Queimadas

As tecnologias de SR têm sido amplamente aplicadas em diversos estudos para investigar a capacidade de produzir estimativas de áreas queimadas e mapear com precisão os limites dos incêndios florestais (GITAS et al., 2004). Desde que os sensores orbitais foram capazes de recobrir grandes áreas com alta frequência temporal, e também disponibilizar informações espectrais além da faixa da região do visível, estas tecnologias passaram a ser valiosas ferramentas para a prevenção, detecção e o mapeamento de incêndios florestais (MITRI; GITAS, 2004).

As condições durante e após o incêndio mudam o espectro de energia refletida e emitida de uma área afetada. Os sensores de satélite de observação da Terra podem usar esta informação para detectar incêndios, quantificar áreas queimadas e determinar a composição e distribuição de plumas de fogo (COCHRANE, 2003).

A utilização das tecnologias de SR para a identificação de queimadas baseia-se, principalmente, em dois subprodutos do fogo, a saber: as modificações biofísicas do material carbonizado e a liberação de calor. Com base nesses subprodutos, as análises podem ser categorizadas em: a) detecção de cicatriz de queimada, e b) detecção de

focos de calor (LIMA, 2013). O primeiro subproduto está relacionado à espacialização das queimadas e na quantificação da extensão das áreas afetadas por este evento, geralmente, utilizando bandas espectrais da região do visível e/ ou associadas às bandas espectrais da região do infravermelho termal. O segundo subproduto refere-se à detecção de focos de calor, geralmente, associada a fogos ativos, utilizando as bandas espectrais da região do infravermelho termal (ANDERSON et al., 2005).

Os procedimentos de detecção e monitoramento de incêndios em escalas locais, continentais e globais têm sido desenvolvidos ao longo de muitos anos por meio de diferentes sistemas sensores (SHIMABUKURO et al., 2015). Em relação à escala global, a demanda por dados mais precisos de área queimada, coletados em longos períodos de tempo, é necessária para determinar se a ocorrência de queimadas e seus impactos estão relacionados às mudanças no clima e às mudanças de uso e cobertura da terra (HAWBAKER et al., 2017). Neste sentido, Mouillot et al. (2014) realizaram uma revisão dos principais produtos globais para áreas queimadas, que incluem dados dos sensores MODIS, TRIM/VIRS, ATSR, SPOT VEGETATION, NOAA-AVHRR, ERS2-ATSR2; e concluíram que há uma demanda dos usuários por dados de área queimada mais precisos. É destacado ainda, pelos autores supracitados, que há a necessidade de se obter dados com uma série temporal mais consistente ao longo do tempo e ter continuidade de sucessivos sensores para que erros de comissão e omissão sejam reduzidos.

Entretanto, os mapeamentos de áreas queimadas baseados em SR, em escala global, ainda apresentam grandes divergências na quantificação da queima de biomassa entre os produtos, tanto em termos de extensão como de localização das áreas queimadas. A detecção de mudanças superficiais causadas pelo fogo em escala global é difícil devido à complexidade, diversidade e grande número de biomas envolvidos (LIBONATI et al., 2015), assim como devido à variabilidade e ao desenvolvimento temporal das características espectrais das cicatrizes de queimada (SHIMABUKURO et al., 2015). Como consequência, estes modelos globais apresentam incertezas nas estimativas e a distribuição espacial de áreas queimadas. Os erros de comissão para áreas queimadas variam na ordem de 42% a 94%, enquanto os de omissão variam de 68% a 93%, dependendo do sensor usado (PADILLA et al., 2015).

Nesse sentido, Lima (2013) observou que apesar das queimadas ocorrerem com grande frequência e afetarem distintas regiões do globo, há uma grande carência de produtos de áreas queimadas em escala regional. No caso da Amazônia, a dificuldade na geração de produtos de áreas queimadas com maior acurácia e detalhe deve-se a diferentes fatores: cobertura de nuvens e presença de sombra de nuvens, que apresentam assinatura espectral similar às áreas queimadas, dinâmica sazonal da floresta, disponibilidade de dados para apenas uma parte da área de estudo, variabilidade e desenvolvimento temporal das características espectrais das áreas queimadas, a própria resolução espacial das imagens e produtos, e métodos usados para detectar as cicatrizes de queimada (MIETTINEN et al., 2013; SHIMABUKURO et al., 2015; ARAGÃO et al., 2016; ANDERSON et al., 2017). Além disso, a ocorrência de incêndios em floresta e em sub-bosque dificulta a estimativa de áreas queimadas para grandes extensões territoriais (MORTON et al., 2013; ANDERSON et al., 2017).

Áreas queimadas iguais ou menores que um pixel do sensor MODIS (>250m), por exemplo, são afetadas pela mistura de alvos, comprometendo a resposta espectral recebida pelo sensor e reduzindo a qualidade da detecção desses eventos (ANDERSON et al., 2005). Portanto, os dados de satélite de média resolução espacial, como os da série Landsat (30m), são mais adequados para a avaliação da área queimada e oferecem meios para analisar a extensão, distribuição e características das áreas queimadas com maior confiabilidade (SHIMABUKURO et al., 2015; ANDERSON et al., 2015).

Entretanto, conforme salientam Miettinen et al. (2013), é difícil obter uma cobertura completa e adequada de imagens de resolução média para o mapeamento de queimadas em grandes áreas de regiões tropicais. Ao mesmo tempo, pode ser mais demorado realizar análises de imagens sobrepostas em grandes áreas com precisão aceitável (SHIMABUKURO et al., 2015).

Neste sentido, a integração de imagens de média resolução espacial pode ser vista como uma possível solução para a detecção de áreas queimadas em imagens de média resolução espacial, ao aumentar a quantidade de imagens disponíveis para uma mesma área de estudo (LATORRE et al., 2007). Todavia, alguns cuidados devem ser tomados ao integrar dados de SR de diferentes fontes, uma vez que diferentes resoluções e formas de aquisição de imagens orbitais podem gerar erros que afetam a qualidade dos processamentos, conforme será discutido na próxima seção.

2.3. Imagens de Média Resolução Espacial

Atualmente, um grande número de sensores orbitais está disponível para o monitoramento global da superfície terrestre, cada um deles com diferentes características espectrais, espaciais e radiométricas. Desta forma, é útil combinar e analisar estes dados e, assim, aproveitar suas diferentes características para melhorar o processo de extração de informações em imagens de satélite (FONSECA; MANJUNATH, 1996). Imagens de multi-sensores podem combinar diferentes resoluções espaciais e temporais para preencher as lacunas de dados de séries temporais e, assim, melhorar o processo de detecção e monitoramento das mudanças na superfície terrestre ao longo do tempo como, por exemplo, o comportamento do fogo e os efeitos pós-fogo na vegetação que podem ser obscurecidos pela presença de nuvens, fumaça e outros aerossóis opticamente espessos (BOSCHETTI et al., 2015; BENDINI et al., 2016).

Entretanto, o uso combinado de imagens de diferentes sensores coloca uma série de desafios conceituais e técnicos, pois as características destes dados diferem em sua configuração orbital, espacial, espectral e temporal (MANDACINI; BITELLI, 2016). Neste caso, é necessário o uso de técnicas de pré-processamento de imagens para uniformizar esses dados (MOUSIVAND et al., 2015).

A combinação de imagens de diversas fontes apresenta potencial para o mapeamento de áreas queimadas na Amazônia, pois inclui a disponibilidade de uma série de sensores com imagens multi-espectrais de média resolução espacial a bordo dos satélites Landsat-8, Sentinel-2 e CBERS-4 (WULDER et al., 2012; DRUSCH et al., 2012; PINHO et al., 2016; MANDANCINI; BITELLI, 2016). Nesse sentido, vários pesquisadores têm colocado esforços para combinar múltiplos sensores no mapeamento de áreas queimadas (RADOUX et al., 2016; BOSCHETTI et al., 2015; HUANG et al., 2016). Por exemplo, Lanorte et al. (2013) aplicando o índice *Normalized Burn Ratio* (NBR) em dados MODIS e ASTER, e Boschetti et al. (2015) usando fusão de dados orientada a objetos em imagens Landsat e MODIS. A Tabela 2.1 mostra alguns sensores orbitais de média resolução espacial que têm sido muito usados no mapeamento de áreas queimadas na Amazônia.

Tabela 2.1 - Sensores de média resolução espacial com potencial para detecção de áreas queimadas na Amazônia.

Satélite/Sensor	Resolução espacial	Resolução temporal	Bandas (μm)	Disponibilidade de datas
Landsat TM	30m 60m	16 dias	0,45-0,52	1984-2011
			0,52-0,60	
			0,63-0,69	
			0,76-0,90	
			1,55-1,75	
			2,08-2,35	
			10,4-12,5	
Landsat-8 OLI	15m 30m 100m	16 dias	0,50-0,68	2013-atual
			0,43-0,45	
			0,45-0,51	
			0,53-0,59	
			0,64-0,67	
			0,85-0,88	
			1,57-1,65	
			2,11-2,29	
			1,36-1,38	
10,60-11,19				
11,50-12,51				
CBERS-4 MUX	20m	26 dias	0,45 - 0,52	2015-atual
			0,52 - 0,59	
			0,63 - 0,69	
			0,77 - 0,89	
Resourcesat-2 LISS-3 e AWiFS	23,5m (LISS-3) 56m (AWiFS)	24 dias	0,52-0,59	2011-atual
			0,62-0,68	
			0,77-0,86	
			1,55-1,70	
Sentinel-2 MSI	10m 20m 60m	5 dias	0,44-0,54	2015-atual
			0,53-0,58	
			0,64-0,68	
			0,76-0,90	
			0,69-0,71	
			0,73-0,74	
			0,76-0,79	
			0,84-0,88	
			1,54-1,68	
			2,08-2,32	
			0,42-0,45	
0,93-0,95				
1,33-1,41				

Fonte: Produzido pelo autor.

2.4. Classificação de Áreas Queimadas

A classificação de imagens é o processo usado para produzir mapas temáticos a partir de imagens digitais. É uma técnica de extração de informações, responsável pela atribuição de significado ou rótulo a um pixel (ou a um conjunto deles) de acordo com suas propriedades e relações, sejam elas espectrais, espaciais, ou outras. Este processo envolve etapas de: extração de feições, treinamento e rotulação (SCHOWENGERDT, 2007; NOVO, 2010).

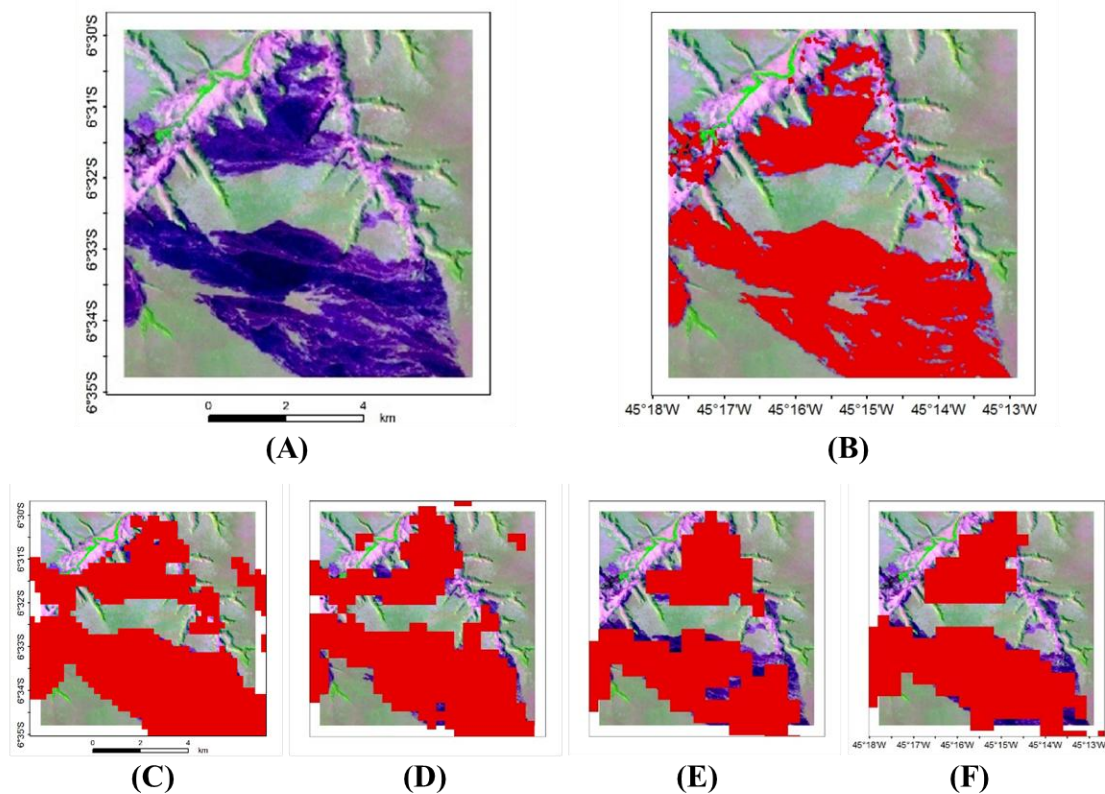
No caso da identificação de áreas queimadas, os principais procedimentos utilizados baseiam-se na aplicação de algoritmos automáticos (ROY et al. 2008; MORTON et al., 2011; LIBONATI et al., 2015), em modelos de mistura espectral e técnicas de interpretação visual (COCHRANE, 1998; ANDERSON et al., 2005; PIROMAL et al., 2008; SHIMABUKURO et al., 2009; Da SILVA CARDOZO et al., 2014; SILVA JÚNIOR et al., 2017).

Em escala global, algumas iniciativas de desenvolvimento de algoritmos automáticos para geração de produtos de áreas queimadas podem ser destacadas, tais como os derivados do sensor MODIS: MODIS MCD45 (ROY; BOSCHETTI, 2008; BOSCHETTI et al., 2015) e MODIS MCD64 (GIGLIO et al., 2016). Outros estudos na região Amazônica têm sido realizados por Anderson et al. (2005), Piromal et al. (2008), Shimabukuro et al. (2009), Lima et al. (2012), CARDOZO et al. (2014), Silva Júnior et al. (2017). Os métodos baseados na fração-sombra derivadas da aplicação do Modelo Linear de Mistura Espectral (MLME) em dados MODIS, TM, ETM+ e OLI tem sido promissores. No entanto, o refinamento dos mapeamentos de áreas queimadas por edição manual é necessário, o que torna o processo de mapeamento mais custoso.

Os erros de detecção de áreas queimadas ocorrem, principalmente, devido à semelhança espectral entre os alvos e também aos erros de omissão e comissão associados à limitação metodológica. Portanto, o desenvolvimento de algoritmos de detecção de áreas queimadas que levam em consideração o tipo de vegetação, solo e clima da região, além da validação e calibração dos dados, podem melhorar os resultados (LIBONATI et al., 2015; LIMA, 2013).

Silva Junior et al. (2017) realizaram a análise comparativa da exatidão dos mapeamentos de alguns produtos globais de áreas queimadas derivados do sensor MODIS em relação ao método baseado em MLME, proposto por Shimabukuro et al. (2009), usando duas cenas Landsat-8 OLI, MODIS MOD09 (250m) e VIIRS-NPP (500m) na Amazônia Legal. Os autores identificaram que os resultados derivados das imagens MODIS e VIIRS apresentaram erros de omissão e comissão elevados ao subestimar as áreas queimadas. Áreas de não queimadas (como por exemplo, sombras formadas pelo relevo, nuvens e corpos hídricos) foram mapeadas como áreas queimadas. A Figura 2.3 ilustra este problema.

Figura 2.3 - Comparativo de classificação de áreas queimadas em uma região da Amazônia, destacando as diferenças de exatidão dos mapeamentos com diferentes fontes de dados de SR.



Produtos de áreas queimadas: (A) Composição R4 G5 B6 do sensor OLI, (B) Classificação MLME da imagem OLI (30m), (C) Classificação MLME da imagem MODIS-MOD09 (250m), (D) Classificação MLME da imagem VIIRS-NPP (500m), (E) Produto MODIS MCD45 (500m), (F) Produto MODIS MCD64 (500m).

Fonte: Adaptado de Silva Júnior *et al.* (2017).

Outros trabalhos têm investigado o potencial das técnicas de GEOBIA e algoritmos de mineração de dados na classificação e detecção de áreas queimadas. Estes métodos também usam índices espectrais para realçar as características espectrais das áreas queimadas. Dentre os estudos, destacam-se:

- Polychroaki e Gitas (2012) mapearam áreas queimadas na Grécia durante os verões de 2007 e 2009 utilizando imagens HRVIR-SPOT-4 (20m) e conseguiram reproduzir a metodologia desenvolvida baseada em objetos para outras áreas da região com bons índices de acurácia ($Kappa > 0,83$).
- Mitrakis et al. (2012) mapearam áreas queimadas e testaram o desempenho de alguns algoritmos comuns de reconhecimento de padrões, tais como self-organizing neuro-fuzzy classifier, *Neural Networks* (redes neurais), *Support Vector Machines* (SVM) e *AdaBoost*. Os resultados tiveram acurácia alta (Exatidão Global $> 93\%$), porém sem diferenças estatísticas significativas entre eles.
- Katagis et al. (2014) investigaram o potencial de um procedimento semiautomático baseado em GEOBIA para reconstrução da história de incêndios em uma área do Mediterrâneo com base em séries temporais de imagens Landsat-MSS, TM e OLI . Os pesquisadores utilizaram índices espectrais (NDVI e NBR) para gerar os dados de referência e os mapas de áreas queimadas tiveram alto índice de exatidão (Exatidão Global $> 94\%$).

Nesta linha de pesquisa, destaca-se o trabalho de Shimabukuro et al. (2015), que consiste na estimativa de áreas queimadas em Mato Grosso baseada em GEOBIA e dados de satélite de média resolução espacial. A metodologia foi considerada mais eficiente do que os métodos convencionais, uma vez que pequenas cicatrizes de queimadas foram detectadas. A Tabela 2.2 apresenta a relação de trabalhos recentes e com bons resultados sobre detecção de áreas queimadas classificados em relação ao método e tipo de dados utilizados.

Tabela 2.2 - Iniciativa de estudos recentes de detecção de área queimada em diferentes escalas, dados de SR, localidades e métodos.

Referências	Principais Técnicas	Tipos de Dados	Localidade
Roy et al. (2008) Morton et al. (2011) Libonatti et al. (2015)	Composição de séries temporais Algoritmos de detecção de áreas queimadas	MODIS/AQUA-TERRA	Global e Brasil
Anderson et al. (2005) Piromal et al. (2008) Shimabukuro et al. (2009) Lima et al. (2012) Da Silva Cardozo et al. (2014) Silva Júnior et al. (2017)	MLME Classificadores Convencionais Interpretação Visual	MODIS/AQUA-TERRA TM/Landsat-5 ETM+/Landsat-7 OLI/Landsat-8	Brasil (Amazônia)
Polychroaki e Gitas (2012) Mitrakis et al. (2012) Katagis et al. (2014)	GEOBIA e mineração de dados	SPOT-4/HRVIR TM/Landsat-5 MSS/Landsat-7 OLI/Landsat-8	Europa (Mediterrâneo)
Shimabukuro et al. (2015)	GEOBIA	TM/Landsat-5	Brasil (Amazônia)

Fonte: Produzido pelo autor.

2.5. Métodos de Processamento Digital de Imagens

Esta Seção apresenta uma descrição resumida das técnicas de processamento digital de imagens que serão utilizadas no procedimento metodológico de detecção de áreas queimadas.

2.5.1. Índices Espectrais

Índices espectrais são técnicas de transformação de imagens de sensoriamento remoto utilizados para realçar a resposta espectral de alvos da superfície terrestre e para avaliar e monitorar diferentes processos de mudanças de cobertura da terra. Estes índices resultam da combinação de respostas espectrais em duas ou mais bandas espectrais do espectro eletromagnético e são amplamente utilizados por sua simplicidade conceitual e eficiência computacional para realçar feições presentes na imagem (HUETE et al., 2002; SCHEPERS et al., 2014).

Os estudos de áreas queimadas utilizam índices espectrais que combinam bandas do infravermelho próximo (NIR), o infravermelho de ondas curtas (SWIR) e o infravermelho térmico (TIR). Estes índices apresentam melhor capacidade de identificação de áreas queimadas em relação aos índices que utilizam apenas as bandas espectrais do visível e do infravermelho próximo (HOLDEN et al., 2005; TRIGG; FLASSE, 2001; SMITH et al., 2007). A Tabela 2.3 apresenta os principais índices espectrais usados na detecção de áreas queimadas.

As características reflexivas e térmicas das áreas queimadas levaram ao uso de vários índices espectrais para a discriminação de áreas queimadas (SMITH et al., 2007). O comportamento espectral das áreas queimadas é caracterizado pela diminuição da reflectância nas bandas do visível e na banda do infravermelho próximo, e também no aumento da reflectância nas bandas de ondas curtas do infravermelho médio, de acordo com Pereira e Setzer (1993) para imagens Landsat-5 TM na região amazônica. Os estudos de Pereira (1999) e Libonati et al. (2012) também consideraram o intervalo entre a região visível e o infravermelho de ondas curtas como as regiões mais recomendadas para mapeamento de áreas queimadas.

No Brasil, alguns autores avaliaram índices espectrais, usando imagens Landsat-5, para identificação de queimadas em uma região do Cerrado (MELCHIORI et al, 2015;

PEREIRA et al, 2016). Vedovato et al. (2015) compararam os índices NBR e o MLME para detecção de queimadas na região Amazônica a partir de imagens Landsat-8 OLI. Embora os resultados para os dois métodos apresentem alta acurácia (Exatidão Global superior a 76%), os erros de omissão e comissão foram maiores para o índice NBR nas áreas com pequenas manchas de área queimada.

Nesse sentido, vários trabalhos têm avaliado o potencial dos índices espectrais para o mapeamento de áreas queimadas. A Tabela 2.4 apresenta uma lista de trabalhos que usam os índices espectrais para mapeamento de queimadas.

Tabela 2.3 - Principais índices espectrais para detecção de áreas queimadas e vegetação.

Índices Espectrais	Sigla	Formula	Referência
<i>Simple Ratio</i>	SR	$\frac{\rho\text{NIR}}{\rho\text{Red}}$	Birth e McVey (1968)
<i>Normalized Difference Vegetation Index</i>	NDVI	$\frac{(\rho\text{NIR} - \rho\text{Red})}{(\rho\text{NIR} + \rho\text{Red})}$	Rouse et al. (1973)
<i>Soil Adjusted Vegetation Index</i>	SAVI	$\frac{(1 + L)(\rho\text{NIR} - \rho\text{Red})}{(\rho\text{NIR} + \rho\text{Red} + L)}$	Huete (1988)
<i>Enhanced Vegetation Index</i>	EVI	$\frac{G(\rho\text{NIR} - \rho\text{Red})}{(L + \rho\text{NIR} + C_1\rho\text{Red} - C_2\rho\text{B})}$	Huete et al. (2002)
<i>Burned Area Index</i>	BAI	$\frac{1}{(0.1 - \rho\text{Red})^2 + (0.06 - \rho\text{NIR})}$	Chuvieco et al. (2002)
<i>Burned Area Index Modified</i>	BAIM	$\frac{1}{(\rho\text{NIR} - 0.05)^2 + (\rho\text{LSWIR} - 0.2)^2}$	Martín et al. (2006)
<i>Normalized Burn Ratio</i>	NBR	$\frac{\rho\text{NIR} - \rho\text{SWIR}}{\rho\text{NIR} + \rho\text{SWIR}}$	Key e Benson (2005)
<i>Mid-Infrared Burn Index</i>	MIRBI	$10 \rho\text{LSWIR} - 9.8 \rho\text{SWIR} + 2$	Trigg e Flasse (2001)
<i>Char Soil Index</i>	CSI	$\frac{\rho\text{NIR}}{\rho\text{LSWIR}}$	Smith et al. (2007)
<i>Vegetation Index Number 6 Thermal</i>	VI6T	$\frac{\rho\text{NIR} - \text{STIR}}{\rho\text{NIR} + \text{STIR}}$	Holden et al. (2005)
<i>Normalized Burn Ratio Thermal</i>	NBRT	$\frac{\rho\text{NIR} - (\rho\text{SWIR} \text{ STIR})}{\rho\text{NIR} + (\rho\text{SWIR} \text{ STIR})}$	Holden et al. (2005)

ρB = banda de reflectância do azul; ρRed = banda de reflectância do vermelho; ρNIR = banda de reflectância do infravermelho próximo; ρLSWIR = banda de reflectância do infravermelho de ondas longas; ρSWIR = banda de reflectância do infravermelho de ondas curtas; L (SAVI) = valor constante de ajuste de solo (0,5); L (EVI) = valor constante (1,0); G = valor constante (2,5); C_1 = valor constante (6,0); C_2 = valor constante (7,5); STIR = escala de brilho em temperatura = valor da banda TIR dividido por 10 000.

Fonte: Produzido pelo autor.

Tabela 2.4 - Estudos recentes de mapeamento de áreas queimadas usando índices espectrais.

Referência	Índices Espectrais	Dados de SR	Localidade
Lasaponara (2006)	NDVI, NDII, ALBEDO, GEMI, SAVI, BAI	SPOT- Vegetation	Mediterrâneo
Veraverbeke et al. (2011)	NDVI, GEMI, EVI, VI3, SAVI, MSAVI, BAI, GEMI3, NBR, CSI, MIRBI, NDVIT, SAVIT, NBRT, CSIT, V16T, NSEv1, NSEv2, NSTv1, NSTv2	MODIS/ASTER (<i>Airborne Simulator Data - MASTER</i>)	California (EUA)
Schepers et al. (2014)	NDVI, GEMI, EVI, SAVI, MSAVI, BAI, NBR, CSI, MIRBI	<i>Airborne Imaging Spectroscopy (APEX)</i>	Bélgica (Europa)
Bastarrika et al. (2014)	NDVI, BAIM, GEMI, NBR, MIRBI	Série Landsat	EUA
Melchiori et al. (2015)	NDVI, NBRL, NBRSL, BAIMS, BAIML, MIRBI, W index	Landsat-5 TM	Cerrado
Vedovato et al. (2015)	NBR	Landsat-8 OLI	Amazônia
Pereira et al. (2016)	BAI, NBR, MIRBI, NDVI, SAVI, CSI, NBR2, NDMI, EVI, W index	Landsat-5 TM	Cerrado

Fonte: Produzido pelo autor.

2.5.2. GEOBIA

Os recentes avanços tecnológicos dos sistemas sensores e das técnicas de processamento digital de imagens têm permitido a extração de informações de objetos e fenômenos da superfície terrestre com maior precisão e menor custo operacional, o que explica a diversidade de métodos e técnicas de classificação automática de imagens (BLASCHKE; KUX, 2007; BLASCHKE, 2010; BLASCHKE et al., 2014).

Hay e Castilla (2008) definem GEOBIA (Análise Baseada em Objetos Geográficos – do inglês *Geographic Object-Based Image Analysis*) como uma subdisciplina da Ciência da Informação Geográfica (*GIScience*) dedicada ao desenvolvimento de métodos automáticos de particionamento de imagens de SR em imagens-objetos significativos, e a avaliação de suas características espectrais, espaciais e temporais em diversas escalas, com o intuito de gerar uma nova informação geográfica em formato geoespacial. Esta abordagem também permite que analistas utilizem os seus conhecimentos sobre o ambiente e desenvolvam modelos que representem de forma mais adequada os objetos e as suas relações (PINHO et al., 2012).

Na abordagem GEOBIA, primeiramente, as regiões na imagem são identificadas com base em algoritmos de segmentação. Em seguida, são extraídos atributos espectrais, de vizinhança, de textura e características descritivas espaciais para depois, ao combinar regiões e atributos, realizar uma classificação destes objetos (KÖRTING et al., 2013). As vantagens da abordagem GEOBIA consistem na possibilidade de análise por regiões, a combinação de diferentes atributos para caracterizar as regiões, assim como na combinação de diferentes algoritmos de classificação (HAY; CASTILLA, 2008).

No entanto, Li et al. (2016) salientam que a escolha de um classificador adequado para este tipo de abordagem ainda é um desafio, devido à diversidade de fontes de dados, do tamanho de conjuntos de amostras de treinamento e atributos, da seleção de parâmetros de segmentação (escala/tamanho dos objetos) e da mistura espectral dos objetos que acarretam incertezas na comparação entre métodos. Além disso, esta abordagem apresenta alta complexidade computacional dos processos de segmentação de imagens e de extração de atributos (PINHO et al., 2012).

Entretanto, tomados os devidos cuidados na construção do modelo de classificação baseado em GEOBIA, os resultados podem ser melhores do que os métodos baseados em pixel. Além de possibilitar refinar os mapeamentos em diferentes escalas, especialmente em imagens de alta resolução espacial (BASTARRIKA et al., 2011; BLASCHKE et al., 2014). Nesse contexto, a aplicação deste método para investigar áreas queimadas em imagens de média resolução espacial, apoiado pelo conhecimento do especialista, apresenta-se como uma ferramenta promissora para a construção de modelos refinados de detecção de áreas queimadas.

Além disso, a possibilidade de extração de informações dos objetos permite que métodos de reconhecimento de padrões baseados em regras sejam também investigados. Desta forma, algoritmos de reconhecimento de padrões podem ser empregados e treinados, dado um conjunto com grande volume de informações que caracterizam determinado objeto, por meio das técnicas de mineração de dados.

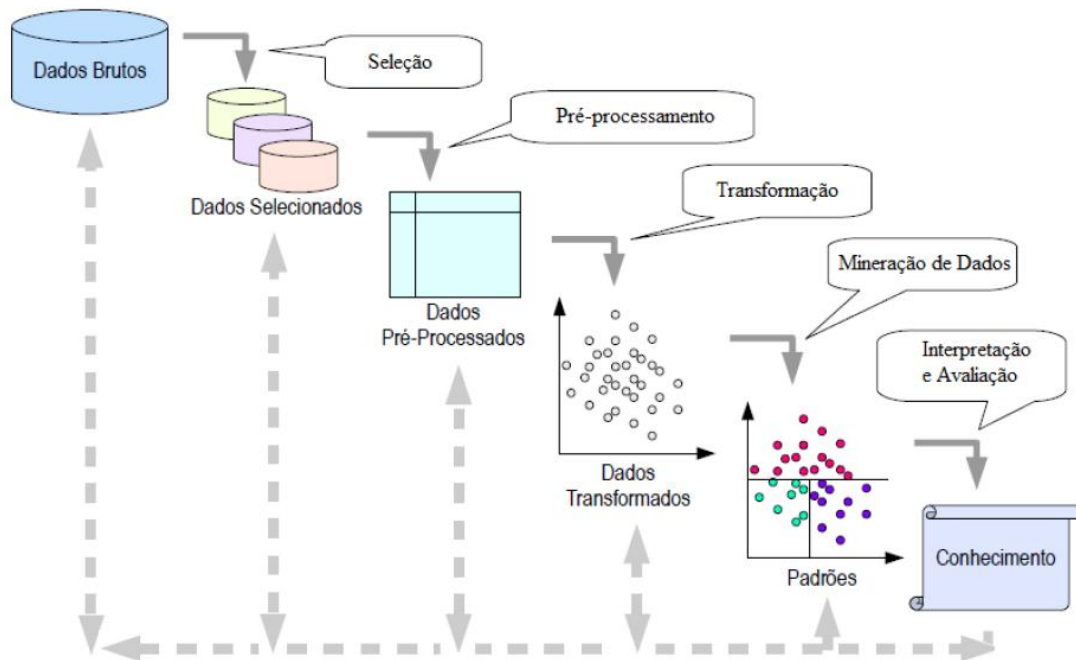
2.5.3. Mineração de Dados

A mineração de dados (do inglês *Data Mining* - DM) pode ser definida como o processo de descoberta de padrões em dados de forma automática ou semiautomática (WITTEN et al., 2016). Para Fayyad et al. (1996), a mineração de dados é uma etapa do processo de descoberta de conhecimento que consiste em aplicar algoritmos de análise e descoberta que produzem uma enumeração particular de padrões (ou modelos) sobre os dados. Os padrões descobertos devem ser significativos na medida em que levam a alguma vantagem - por exemplo, de economia de tempo e custo computacional (WITTEN et al., 2016).

Os avanços tecnológicos e a crescente quantidade de dados coletados e armazenados em grandes e numerosos *data-centers* e repositórios, superam em muito a capacidade humana de compreender, analisar e gerar informações sem ferramentas poderosas para auxiliar nesta tarefa (HAN; KAMBER, 2012). Desta necessidade que emerge o campo da descoberta de conhecimento em bancos de dados (do inglês *Knowledge Discovery in Databases* – KDD) que consiste em uma nova geração técnicas computacionais e ferramentas para ajudar a extrair informações úteis (conhecimento) a partir de grandes volumes de dados digitais (FAYYAD et al., 1996).

As principais etapas deste processo são: seleção de dados, pré-processamento, transformação, mineração de dados, interpretação e avaliação (FAYYAD et al., 1996) (Figura 2.4). É importante salientar que o KDD não é um processo direto, pois ele é caracterizado pelas interconexões entre as etapas. Da entrada para saída, alguns passos podem ser repetidos para refinar a relação entre dados e padrões (KÖRTING, 2012).

Figura 2.4 - Processo da descoberta de conhecimento em bases de dados (KDD).



Fonte: Adaptado de Fayyad et al. (1996); Neves (2017).

A mineração de dados é uma etapa essencial no processo de descoberta do conhecimento, uma vez que possibilita descobrir os padrões ocultos ou de difícil discernimento para a avaliação (HAN; KAMBER, 2012). Segundo Fayyad et al. (1996), a mineração de dados busca por padrões de interesse em uma forma representacional específica ou um conjunto de tais representações, e envolve o ajuste de modelos ou a determinação de padrões a partir de dados observados.

Na área de SR, o aumento da disponibilidade de imagens e dados de observação da terra têm possibilitado estudos cada vez mais complexos. Por outro lado, tem gerado um volume de dados cada vez maior a ser processado e analisado. Nesse sentido, as técnicas de mineração de dados, muitas vezes, são necessárias para facilitar a extração automática e análise de padrões de interesse nos dados (TAN et al., 2001).

Na mineração de dados, as etapas de extração e seleção de atributos são fundamentais para melhorar o desempenho dos algoritmos (KUMAR; MINZ, 2014). A etapa de seleção de atributos projeta estes em um novo espaço com menor dimensionalidade, de forma que novos atributos são construídos a partir de combinações dos originais. A predileção destes elementos visa selecionar um pequeno subconjunto de atributos que minimizam a redundância e maximizam a relevância para um alvo, como os rótulos de classe na classificação (TANG et al., 2013).

A maioria dos métodos de mineração de dados baseia-se em técnicas e testes de aprendizado de máquinas, reconhecimento de padrões e estatísticas: classificação, agrupamento (*clustering*), regressão, entre outros (FAYYAD et al., 1996). Eles podem ainda ser subdivididos em métodos supervisionados e não supervisionados.

Nos métodos supervisionados, os alvos de interesse são definidos de antemão (classes pré-definidas). A partir destas classes, amostras são coletadas e fornecidas ao algoritmo como exemplares ótimos que devem ser utilizados para identificação de seus pares, definindo assim, a etapa de treinamento do algoritmo minerador. Dos métodos supervisionados, destacam-se: os métodos de regressão, as árvores de decisão (sendo o algoritmo C4.5 (QUINLAN, 1993) um dos mais conhecidos), as florestas aleatórias (*Random Forest*) (BREIMAN, 2001), as redes neurais artificiais (*Artificial Neural Network*), o *Support Vector Machine* (SVM) e os algoritmos baseados em lógica *fuzzy* (WU et al., 2008).

Em contrapartida, a abordagem não supervisionada dispensa amostras de treinamento rotuladas a priori, buscando estruturas e padrões de agrupamentos (clusters) para a definição das classes de interesse (LAROSE; LAROSE, 2014). O método não supervisionado mais comum consiste no agrupamento, e os principais algoritmos de mineração de dados são: k-médias (*k-means*) e mapas auto-organizáveis (*Self Organizing Maps*) (WU et al., 2008).

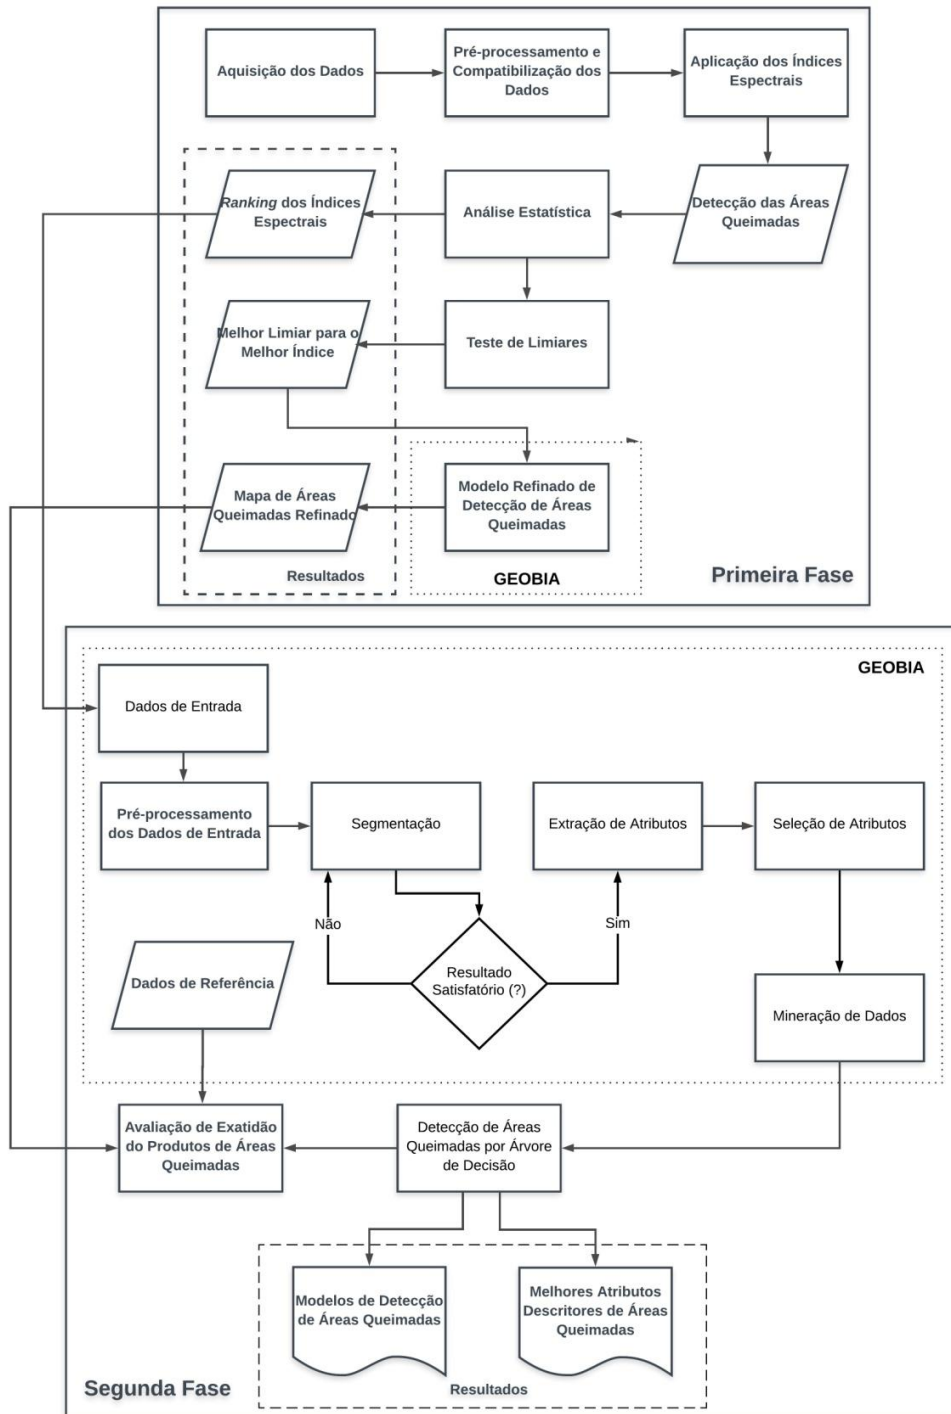
Após o processamento e a construção de modelos preditivos derivados da mineração de dados, a exatidão do modelo deve ser avaliada. Para isto, existem algumas técnicas para verificar a acurácia dos modelos resultantes desses algoritmos, tais como: a matriz de confusão, taxa de acerto (ou erro), coeficiente de determinação (R^2), erro médio quadrático, falsos positivos, falsos negativos e o índice Kappa (LAROSE; LAROSE,

2014). Em estudos mais recentes de mapeamento de áreas queimadas, os principais métodos de avaliação de exatidão dos modelos de classificação são baseados em matrizes de confusão e quantificados por métricas estatísticas derivadas das mesmas, tais como o Coeficiente Dice e os Erros Relativos (PADILLA et al., 2015; PADILLA et al., 2017).

3 METODOLOGIA

A Figura 3.1 apresenta o fluxograma da metodologia proposta neste trabalho. O presente estudo foi dividido em duas grandes fases (Seções 3.3 e 3.4), que serão detalhadas posteriormente.

Figura 3.1 - Fluxograma das etapas da pesquisa.

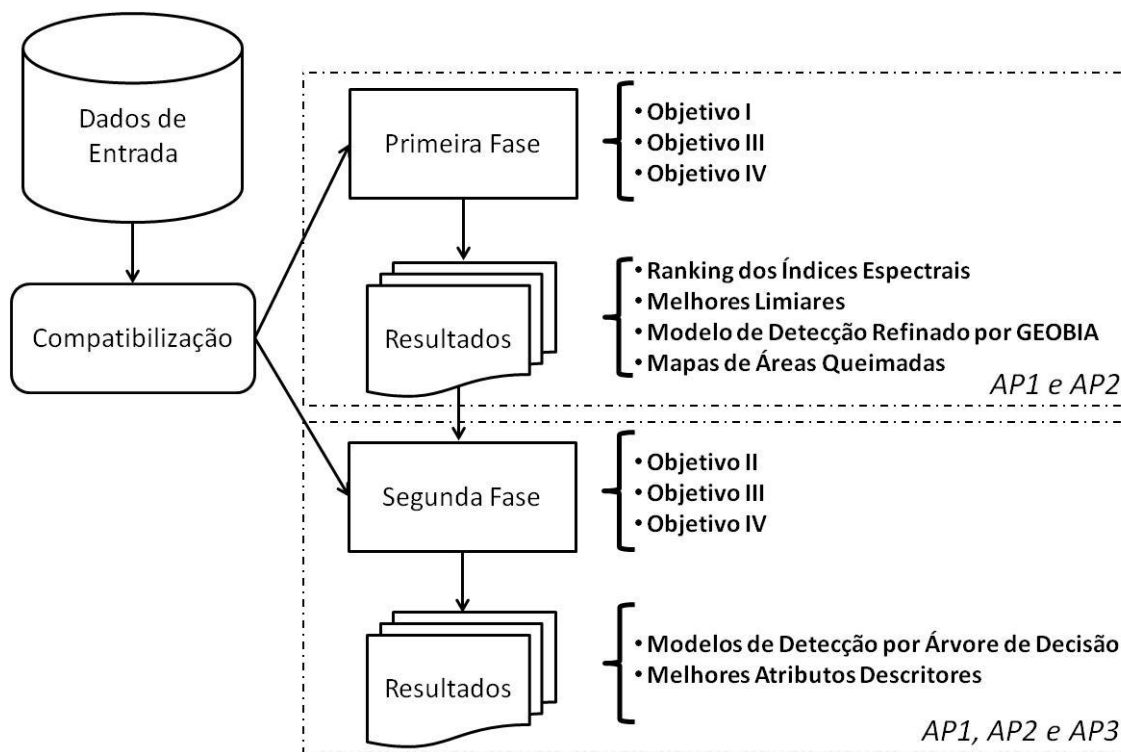


Fonte: Produzido pelo autor.

3.1. Desenho Amostral

O desenho amostral com as principais etapas para responder aos objetivos deste estudo é apresentado na Figura 3.2.

Figura 3.2 – Desenho amostral da pesquisa.



Fonte: Produzido pelo autor.

3.2. Áreas de Estudo

As áreas de estudos (Figura 3.3) selecionadas consistem em três Áreas Pilotos (APs) distribuídas em três estados da Amazônia brasileira: Pará (AP1), Acre (AP2) e Rondônia (AP3). Para a primeira fase da metodologia, apenas as AP1 e AP2 foram utilizadas devido à possibilidade de maior exploração dos índices espectrais em imagens Landsat-8 OLI e Sentinel-2.

A escolha destas áreas baseou-se na disponibilidade das imagens de média resolução espacial e na ocorrência de focos de queimadas durante a seca em 2015 e 2016 (JIMÉNEZ-MUÑOZ et al., 2016). Para verificar a ocorrência de queimadas nas APs, foram utilizados os dados de focos de calor registrados para o mês de aquisição das imagens, com base nos sensores de referência NOAA-AVHRR Noite e AQUA/MODIS UMD Tarde (INPE, 2016). Além disso, o recorte espacial das áreas de estudo foi

definido também com base na sobreposição das cenas Landsat-8 OLI e Sentinel-2 MSI e na distribuição espacial das queimadas na região amazônica, com diferentes padrões de queimadas e contextos locais (Figura 3.4).

A terceira Área Piloto (AP3), localizada em Rondônia, foi utilizada apenas na segunda fase da metodologia (item 3.2), uma vez que para identificação dos atributos descritores das áreas queimadas, diferentes padrões de áreas queimadas deveriam ser incluídos nos experimentos. A seleção da AP3 baseou-se nos mesmos critérios das demais áreas. No entanto, o recorte espacial da AP3 foi definido com base na sobreposição das cenas Landsat-8 OLI e CBERS-4 MUX. As principais características das áreas de estudo estão resumidas na Tabela 3.1.

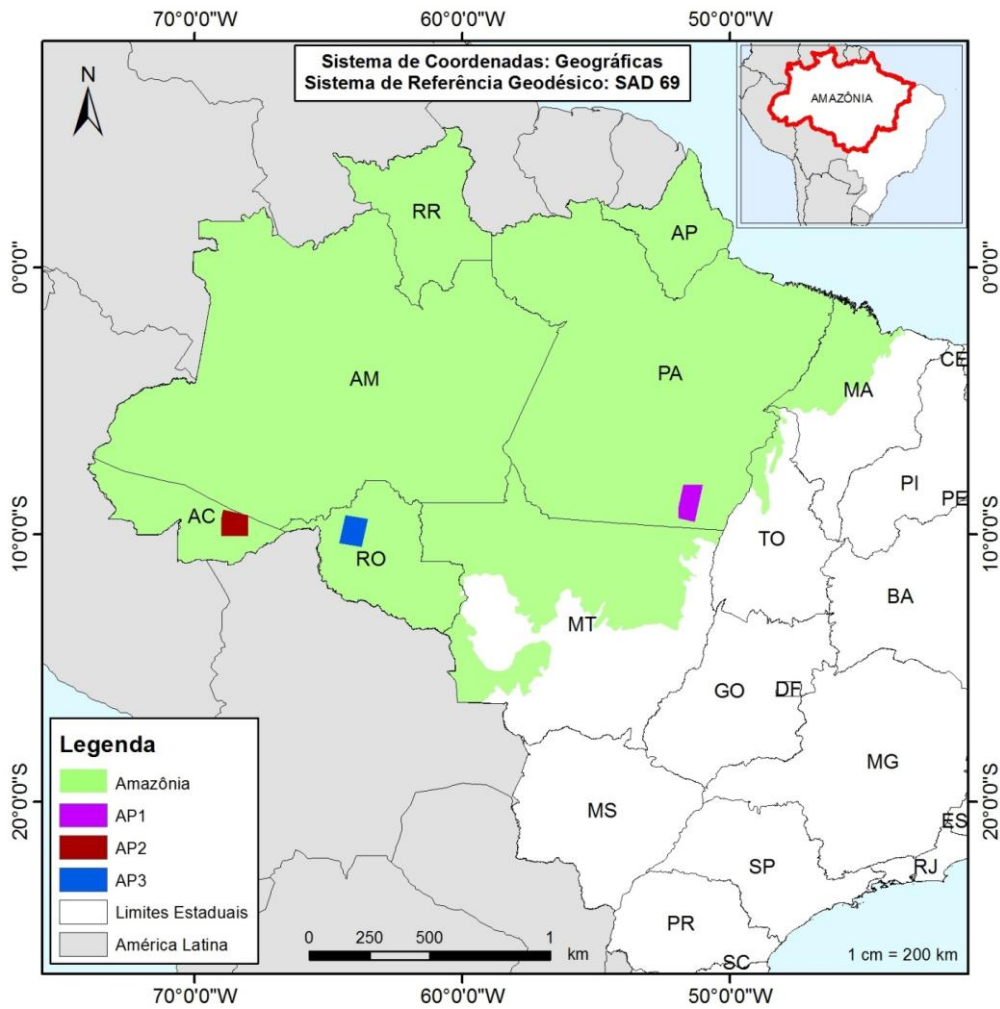
Nessas regiões, as principais coberturas da terra são compostas por florestas, pastagens e áreas agropecuárias. De acordo com o projeto TerraClass (ALMEIDA et al., 2016), no ano de 2014, as principais classes de cobertura da terra na AP1 foram florestas (68,65%) e pastagens (24,98%), na AP2 a principal classe de cobertura era floresta (97,37 %), e na AP3 as principais classes foram floresta (53,16%) e pastagens (32,50%). O número de focos de calor registrados para o mês de aquisição de cada AP foi de 1158 para AP1, 620 para AP2 e 3466 para AP3 (Figura 3.4).

As características climáticas da Amazônia apresentam, predominantemente, clima equatorial quente e úmido, com dois períodos anuais bem definidos: seco e úmido. A temperatura média da região está entre 24°C e 26°C, com uma amplitude térmica sazonal de 1 a 2°C e umidade relativa em torno de 80%. A precipitação média da Amazônia é de 2300 mm/ano, podendo chegar a 3500 mm/ano algumas áreas (FISCH et al., 1998; NOBRE et al., 2009). A vegetação da Amazônia é composta predominantemente por Floresta Ombrófila Densa, típicas florestas tropicais com alto grau de umidade. Além desta, existem outras formações de menor extensão na Amazônia: Campinaranas, Floresta Estacional Sempre-Verde e Floresta Ombrófilas Abertas (IBGE, 2012).

Na maior parte da região amazônica, as queimadas tendem a intensificar nos meses de julho a outubro, com picos no mês de setembro (ARAGÃO et al., 2008). Este período corresponde à estação seca com precipitação mensal abaixo de 100 mm, principalmente nas partes sul e leste da Amazônia. Em geral, as queimadas estão concentradas ao longo

do arco do desmatamento, onde a atividade humana é intensa e a ignição antropogênica da ocorrência de incêndios está presente (ARAGÃO et al., 2008; ARAGÃO et al., 2016).

Figura 3.3 - Localização das áreas de estudo (APs).



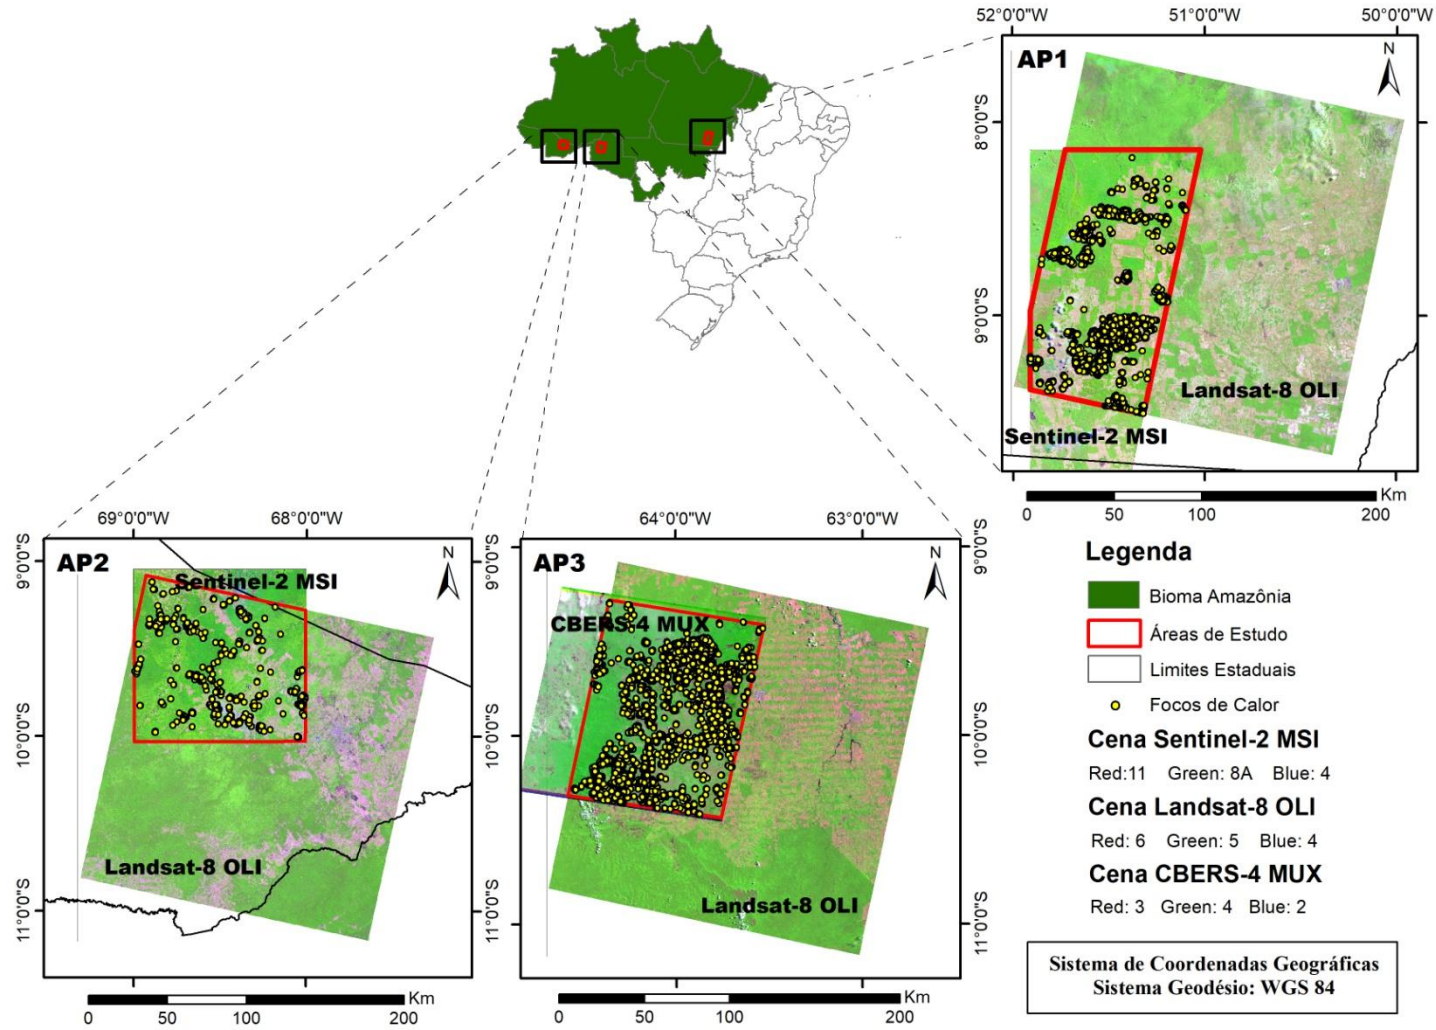
Fonte: Produzido pelo autor.

Tabela 3.1 - Descrição das características das áreas pilotos (APs).

Áreas de Estudo	Contexto das queimadas	Uso e cobertura da terra	Referências
AP1	A ocorrência de queimadas nesta região está intimamente relacionada ao desmatamento e ao uso do fogo para manutenção do pasto que, por vezes, também atinge áreas florestais.	O surgimento dos municípios nesta região está relacionado à abertura de estradas, principalmente após a construção da rodovia BR 163 (Cuiabá-Santarém) e devido aos projetos de colonização encorajados pelo governo federal na década de 1970. As principais atividades econômicas da região são a pecuária e agricultura.	Guerra et al. (2010) Silva et al. (2013)
AP2	A ocorrência de queimadas na região é impulsionada pelo desmatamento e pelo extrativismo vegetal, que geram fontes de ignição principalmente em áreas próximas à floresta.	O histórico de ocupação da região concentrou-se ao longo da rodovia AC-090 e suas ramificações. Ao longo dessas estradas existem assentamentos rurais, pólos agroflorestais e áreas de gestão, cujas principais atividades são o extrativismo vegetal, a agricultura familiar e a pecuária extensiva.	Alencar et al. (2006) Silva et al. (2008)
AP3	A ocorrência de queimadas está relacionada ao processo de desmatamento, com a prática do uso do fogo associado ao gerenciamento de pastagens e áreas agrícolas contribuindo para eliminar a biomassa da floresta densa.	A região é caracterizada pelo crescimento da indústria da madeira a partir de políticas públicas nos anos 1960 e pelas ocupações ao longo de rodovias que permitiram o acesso de agricultores e camponeses. Nesta região as principais atividades econômicas estão relacionadas à extração de madeira e culturas permanentes diversificadas.	Da Silva Cardozo et al. (2014)

Fonte: Produzido pelo autor.

Figura 3.4 - Localização e recorte espacial das APs.



Fonte: Produzido pelo autor.

3.3. Primeira Fase

A primeira fase da metodologia consiste na avaliação de índices espectrais para a detecção de áreas queimadas em duas áreas de estudo (AP1 e AP2) e em duas imagens Landsat-8 OLI e Sentinel-2 MSI. Esta fase indica os melhores índices espectrais, os melhores limiares para identificação de áreas queimadas e, por fim, a construção de um modelo refinado de detecção de áreas queimadas baseado em GEOBIA. As etapas desta primeira fase são apresentadas a seguir.

3.3.1. Aquisição dos dados

Os dados utilizados são apresentados na Tabela 3.2. As cenas Landsat-8 OLI (*Worldwide Reference System2 – WRS-2, Path/Row 002/67 (AP1) 224/66 (AP2) e 232/67 (AP3)*), datadas de 24 de agosto de 2016 (AP1), 27 de agosto de 2016 (AP2) e 18 de setembro de 2015 (AP3), foram adquiridas do sítio do Serviço Geológico dos Estados Unidos (*United State Geological Survey - USGS*) (disponível gratuitamente em <https://www.earthexplorer.usgs.gov/>) em reflectância de superfície (*High Level Quality*) com correção radiométrica, geométrica e atmosférica no sistema de projeção cartográfica UTM/WGS84 (VERMOTE et al., 2016).

As cenas Sentinel-2 MSI foram adquiridas na mesma data que a imagem Landsat-8 OLI para AP1 e AP2, respectivamente, no dia 27 de agosto de 2016, do sítio *Copernicus Scientific Data Hub* (Agência Espacial Europeia - *European Space Agency - ESA*) (disponível gratuitamente em <http://www.scihub.copernicus.eu/>) como produto *Top-Of-Atmosphere (TOA) Level-1C (L1C)* com correção radiométrica e geométrica no sistema de projeção cartográfica UTM/WGS84.

A cena CBERS-4 MUX (*Worldwide Reference System - WRS, Path/Row 176/111*) foi adquirida na data mais próxima possível da imagem Landsat-8 OLI (AP3), no dia 14 de setembro de 2015, do portal do Catálogo de Imagens da Divisão de Geração de Imagens (DGI) do INPE (disponível gratuitamente em <http://www.dgi.inpe.br/catalogo/>).

Tabela 3.2 - Dados de sensoriamento remoto adquiridos.

Área de Estudo	Localização	Sensor	Cena	Data	Horário de aquisição do sensor
AP1	Pará	Landsat-8 OLI	224/66	27/08/2016	13:31 UTC
		Sentinel-2 MSI	22DLR	27/08/2016	13:51 UTC
		Sentinel-2 MSI	22DLQ	27/08/2016	13:52 UTC
AP2	Acre	Landsat-8 OLI	002/67	24/08/2016	14:39 UTC
		Sentinel-2 MSI	19LEK	24/08/2016	14:47 UTC
AP3	Rondônia	Landsat-8 OLI	232/67	18/09/2015	14:21 UTC
		CBERS-4 MUX	176/111	14/09/2015	14:44 UTC

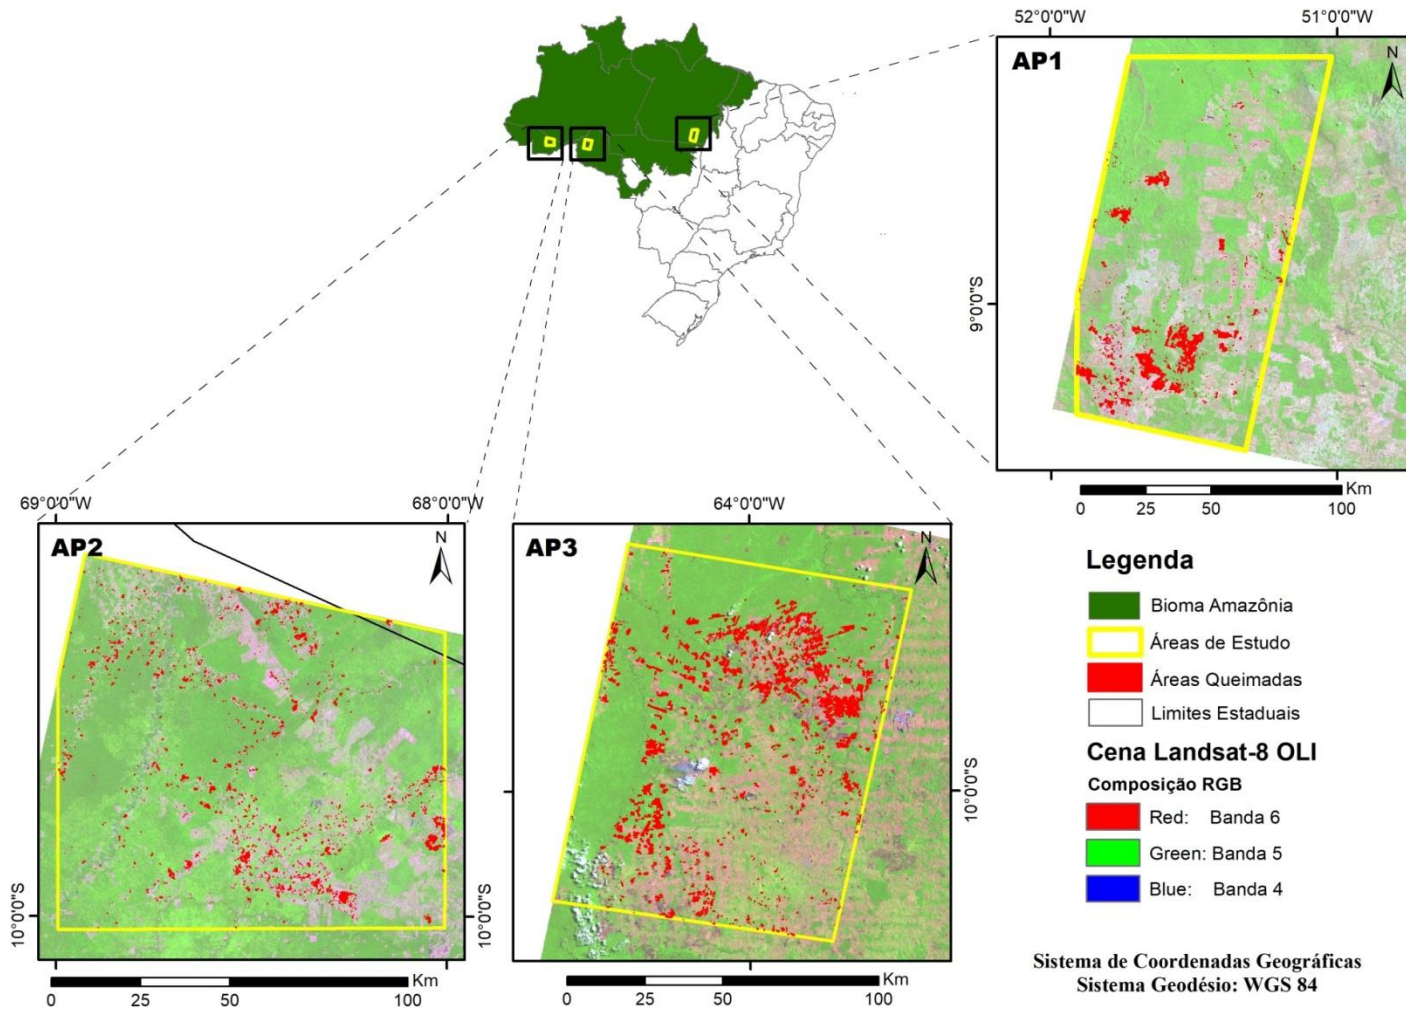
Fonte: Produzido pelo autor.

3.3.2. Dados de Referência

Os dados de referência foram produzidos por um especialista, utilizando as mesmas imagens adquiridas (Seção 3.3.1) e de forma independente, com base nas metodologias de Anderson et al. (2005) e Shimabukuro et al. (2009) - gerando assim os mapas de áreas queimadas para as APs (Figura 3.5). Para isso, o Modelo Linear de Mistura Espectral (MLME) (SHIMABUKURO; SMITH, 1991), seguido de uma classificação não-supervisionada (algoritmo k-médias) e uma edição manual foram aplicados. A edição manual de imagem na pós-classificação foi realizada por um intérprete experiente, usando a composição RGB de cores naturais das imagens multi-espectrais correspondentes para refinar o mapeamento (ANDERSON et al., 2015). Esta etapa minimiza os erros de omissão e comissão normalmente produzidos por qualquer algoritmo de classificação (ALMEIDA-FILHO; SHIMABUKURO, 2002).

Outros trabalhos também aplicaram esta mesma metodologia para diferentes áreas de estudo na Amazônia brasileira e obtiveram alta precisão nos mapeamentos de áreas queimadas (PIROMAL et al., 2008; LIMA et al., 2012; Da SILVA CARDOZO et al., 2014 e SHIMABUKURO et al., 2015). Nestes estudos, as áreas de queimadas mapeadas foram consideradas como áreas de cicatrizes de queimadas recentes (ANDERSON et al., 2015).

Figura 3.5 - Distribuição espacial das áreas queimadas de referência nas APs.



Fonte: Produzido pelo autor.

3.3.3. Pré-processamento e Compatibilização dos Dados

Inicialmente, todas as bandas MSI do Sentinel-2 foram importadas para a plataforma SNAP (*Sentinel Application Platform*) disponibilizada pela ESA para a correção atmosférica. Esta correção é realizada pelo processador *Sen2Cor* (MAIN-KNORN et al., 2015; MÜLLER-WILM, 2016), cuja saída do processamento é um produto de reflectância de superfície (*Bottom-Of-Atmosphere* - BOA) Level 2A, reamostrado para uma resolução espacial de 20m. As imagens de saída em reflectância de superfície geradas pelo processador *Sen2Cor* são reamostradas com um tamanho de pixel igual para todas as bandas, com base em três tamanhos, 10m, 20m ou 60m (MÜLLER-WILM, 2016).

No passo seguinte, os dados foram compatibilizados. Foram obtidas as imagens em reflectância de superfície do Landsat-8 OLI e Sentinel-2 MSI para as áreas de estudo (AP1 e AP2) e foi aplicado o método de reamostragem vizinho mais próximo (*Nearest Neighbor*) para redimensionar o pixel das imagens Sentinel-2 de 20 metros para 30 metros – tornando assim todos os produtos espacialmente compatíveis. A seguir, as imagens Landsat-8 OLI e Sentinel-2 MSI, para ambas as áreas de estudo, foram registradas usando a técnica baseada em feições (FONSECA; MANJUNATH, 1996), com Erros Quadráticos Médios (EQM) iguais a 0,21 para AP1 e 0,25 para AP2. Este passo é essencial devido ao desalinhamento relativo em cada uma das imagens, produzido pela forma de aquisição de cada sensor (YAN et al., 2016).

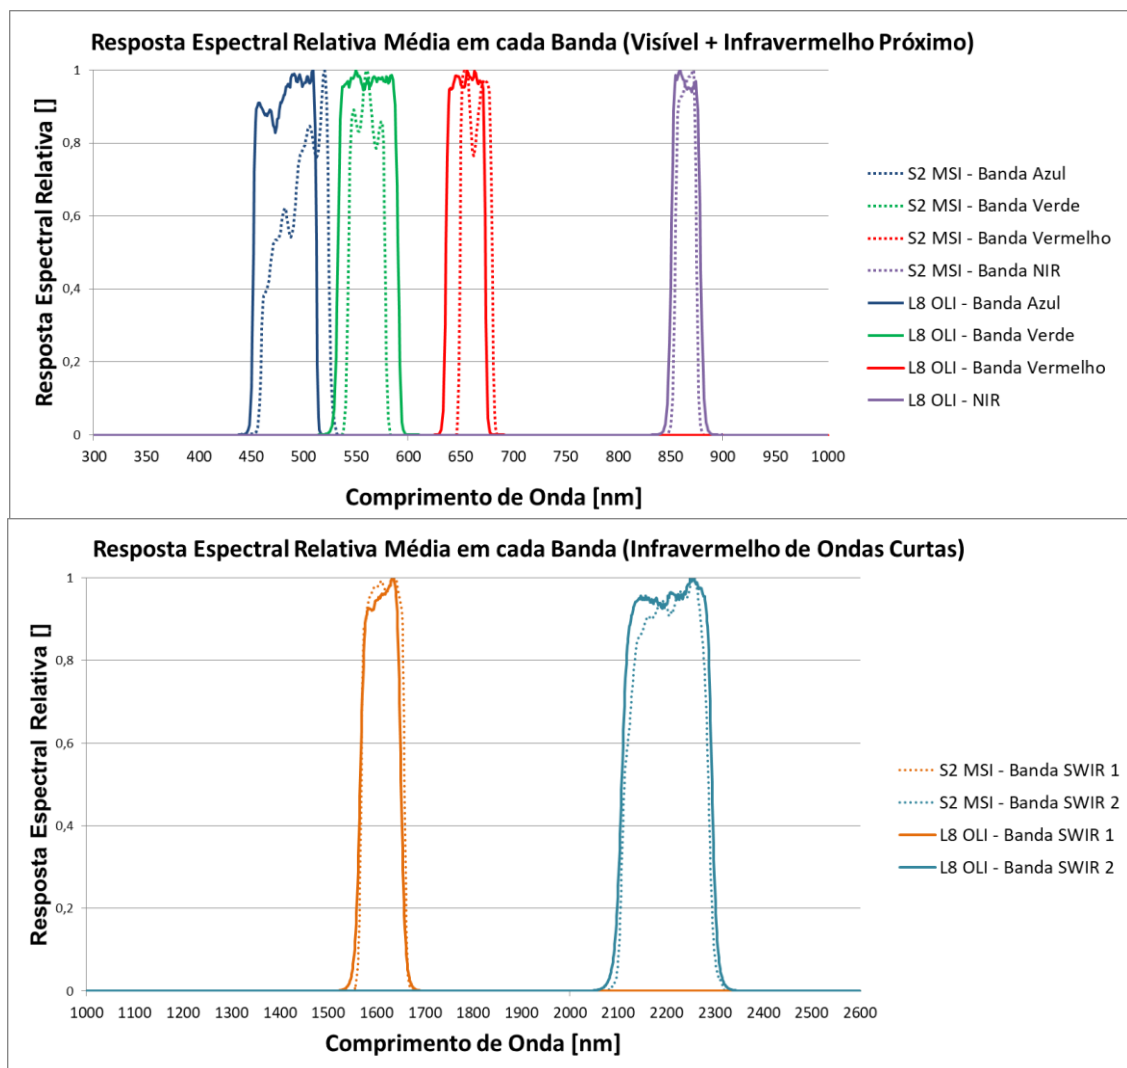
Mandanici e Bitelli (2016), que usaram imagens Landsat-8 e Sentinel-2 integradas, recomendam a compatibilização da resposta espectral e radiométrica dos alvos presentes nas imagens, de acordo com as bandas espectrais correspondentes de cada sensor. Embora as Funções de Resposta Espectral Relativa (do inglês *Relative Spectral Response Function* - RSRF) dos instrumentos não sejam idênticas, elas são equivalentes (Figura 3.6). Desta forma, para este estudo, foram selecionadas seis bandas de Landsat-8 OLI e Sentinel-2 MSI que correspondem ao mesmo intervalo de comprimento de onda em cada sensor (Tabela 3.3). A Figura 3.7 apresenta o perfil espectral de uma área queimada para ambos os sensores supracitados.

Tabela 3.3 - Bandas espectrais das imagens Landsat-8 OLI e Sentinel-2 MSI selecionadas.

Região do Espectro Eletromagnético	Landsat-8 OLI			Sentinel-2 MSI		
	Banda (n°)	Bandas (µm)	Resolução Espacial (m)	Banda (n°)	Bandas (µm)	Resolução Espacial (m)
Azul	2	0,45-0,51	30	2	0.49	10
Verde	3	0,53-0,59	30	3	0.56	10
Vermelho	4	0,64-0,67	30	4	0.66	10
Infravermelho Próximo (NIR)	5	0,85-0,88	30	8A	0.86	20
Infravermelho de Ondas Curtas (SWIR 1)	6	1,57-1,65	30	11	1.61	20
Infravermelho de Ondas Curtas (SWIR 2)	7	2,11-2,29	30	12	2.19	20

Fonte: Produzido pelo autor.

Figura 3.6 - Correspondência da RSRF dos sensores Landsat-8 OLI (L8 OLI) e Sentinel-2 MSI (S2 MSI).



Fonte: Produzido pelo autor.

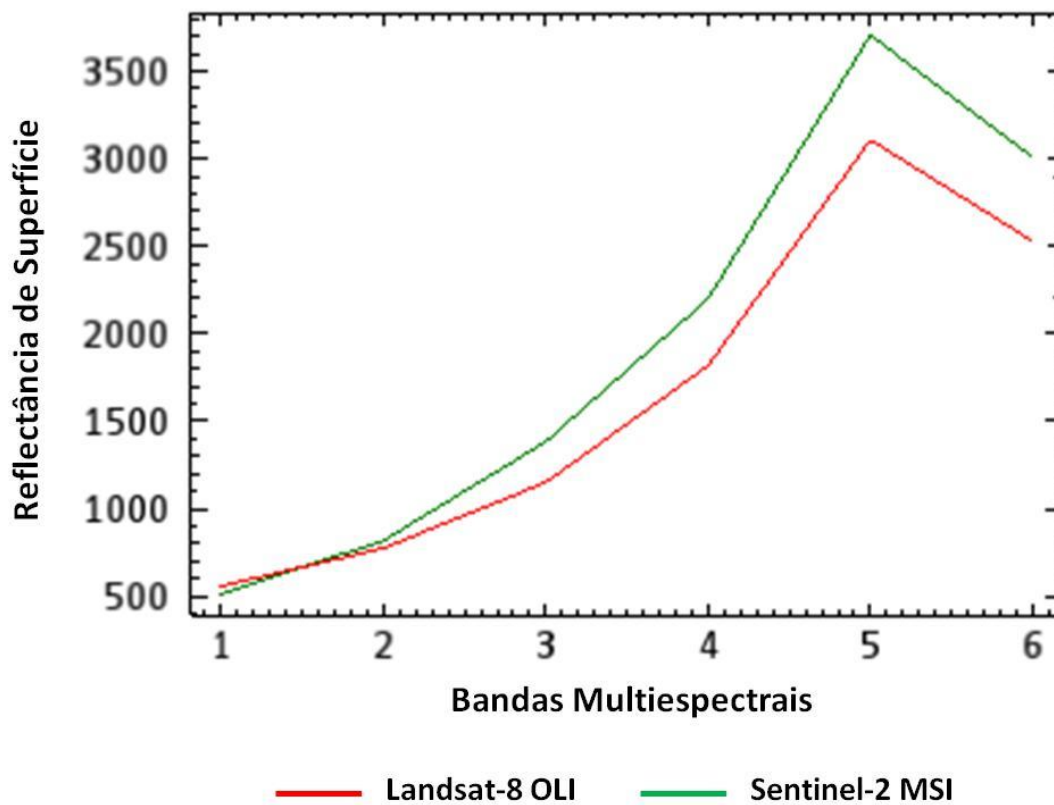
Finalmente, a imagem CBERS-4 MUX (AP3) foi processada e convertida para reflectância em TOA, segundo os procedimentos descritos por Pinto et al. (2016). A correção atmosférica da imagem foi realizada utilizando o modelo 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) (VERMOTE et al., 1997). Assim como foi realizado para AP1 e AP2, a imagem CBERS-4 MUX foi reamostrada de 20m de resolução espacial para 30m e co-registrada (técnica do vizinho mais próximo) com a imagem Landsat-8 OLI (EQM = 0,17), já adquirida como produto BOA para a AP3. A câmera multi-espectral MUX, com resolução temporal de 26 dias e com quatro bandas espectrais, recobre os mesmos intervalos de comprimento de onda do sensor OLI. Desta forma, ambos sensores são compatíveis nos quatro intervalos de comprimento de onda (PINTO et al., 2016; BENDINI et al., 2016). Neste estudo, foram selecionadas quatro bandas espectrais do sensor OLI e MUX, conforme descritas na Tabela 3.4.

Tabela 3.4 - Bandas espectrais selecionadas das imagens Landsat-8 OLI e CBERS-4 MUX.

Região do Espectro Eletromagnético	Landsat-8 OLI			CBERS-4 MUX		
	Banda (n°)	Bandas (µm)	Resolução Espacial (m)	Banda (n°)	Bandas (µm)	Resolução Espacial (m)
Azul	2	0,45-0,51	30	5	0,45-0,52	20
Verde	3	0,53-0,59	30	6	0,52-0,59	20
Vermelho	4	0,64-0,67	30	7	0,63-0,69	20
Infravermelho Próximo (NIR)	5	0,85-0,88	30	8	0,77-0,89	20

Fonte: Produzido pelo autor.

Figura 3.7 – Perfil espectral de uma área queimada nos sensores Landsat-8 OLI (L8 OLI) e Sentinel-2 MSI (S2 MSI).



Fonte: Produzido pelo autor.

3.3.4. Aplicação dos Índices Espectrais

Os índices espectrais são calculados a partir de imagens de satélite e são métodos simples e dinâmicos que permitem o mapeamento adequado tanto de áreas vegetadas quanto áreas afetadas pelo fogo (PEREIRA et al., 2016). Nesta etapa, para a detecção de áreas queimadas foram aplicados 12 índices espectrais (4 índices de vegetação e 5 índices de queimadas) para as áreas de estudo AP1 e AP2. No entanto, devido à existência de duas bandas no infravermelho de ondas curtas (do inglês *Short Wave Infrared* – SWIR) tanto para o sensor OLI quanto MSI, optou-se por testar os índices de queimadas BAIM, CSI e NBR duas vezes cada, de forma adaptada para ambas as imagens. A Tabela 3.5 resume os índices utilizados neste estudo.

Tabela 3.5 - Índices espectrais usados neste estudo.

Índices Espectrais	Siglas	Fórmula	Referência
<i>Simple Ratio</i>	SR	$\frac{\rho_{NIR}}{\rho_{Red}}$	Birth e McVey (1968)
<i>Normalized Difference Vegetation Index</i>	NDVI	$\frac{(\rho_{NIR} - \rho_{Red})}{(\rho_{NIR} + \rho_{Red})}$	Rouse et al. (1973)
<i>Soil Adjusted Vegetation Index</i>	SAVI	$\frac{(1 + L)(\rho_{NIR} - \rho_{Red})}{(\rho_{NIR} + \rho_{Red} + L)}$	Huete (1988)
<i>Enhanced Vegetation Index</i>	EVI	$\frac{G(\rho_{NIR} - \rho_{Red})}{(L + \rho_{NIR} + C_1\rho_{Red} - C_2\rho_B)}$	Huete et al. (2002)
<i>Burned Area Index</i>	BAI	$\frac{1}{(0.1 - \rho_{Red})^2 + (0.06 - \rho_{NIR})}$	Chuvieco et al. (2002)
<i>Burned Area Index Modified</i>	BAIM	$\frac{1}{(\rho_{NIR} - 0.05)^2 + (\rho_{LSWIR} - 0.2)^2}$	Martin et al. (2006)
<i>Normalized Burn Ratio</i>	NBR	$\frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}}$	Key e Benson (2005)
<i>Mid-Infrared Burn Index</i>	MIRBI	$10 \rho_{LSWIR} - 9.8 \rho_{SWIR} + 2$	Trigg e Flasse (2001)
<i>Char Soil Index</i>	CSI	$\frac{\rho_{NIR}}{\rho_{LSWIR}}$	Smith et al. (2007)

ρ_B = banda de reflectância do azul; ρ = banda de reflectância do vermelho; ρ_{NIR} = banda de reflectância do infravermelho próximo; ρ_{LSWIR} = banda de reflectância do infravermelho de ondas longas; ρ_{SWIR} = banda de reflectância do infravermelho de ondas curtas; L (SAVI) = valor constante de ajuste de solo (0.5); L (EVI) = valor constante (1.0) G = valor constante (2.5); C_1 = valor constante (6.0); C_2 = valor constante (7.5).

Fonte: Produzido pelo autor.

Depois disso, os produtos desses índices foram sobrepostos com os dados de referência para analisar os valores que melhor discriminavam as áreas queimadas das áreas não queimadas. Além disso, um histograma para cada índice espectral foi gerado, em cada área de estudo e tipo de imagem, com o objetivo de facilitar a visualização e ajudar nas análises estatísticas de separabilidade.

3.3.5. Análise Estatística

Nesta etapa, o teste de Wilcoxon-Mann-Whitney (teste U de Mann-Whitney) e o índice de separabilidade M foram aplicados para verificar a correlação entre áreas queimadas e não queimadas para cada índice espectral, para garantir a confiabilidade dos dados e

para ranquear os melhores índices espectrais. O teste de Wilcoxon-Mann-Whitney é aplicado para testar a hipótese nula de que duas populações têm funções de distribuição idênticas contra a hipótese alternativa de que as duas funções de distribuição diferem apenas em relação à localização (a mediana) (DEPUY et al., 2005).

O índice de separabilidade M foi utilizado para quantificar a eficácia de cada índice espectral gerado pelas imagens Landsat-8 OLI e Sentinel-2 MSI na discriminação entre áreas queimadas e áreas não queimadas. O índice de separabilidade M (Equação 3.1.5) foi proposto primeiro por Kaufman e Remer (1994), e foi usado em estudos semelhantes por Lasaponara (2006), Smith et al. (2007), Veraverbeke et al. (2011), Schepers et al. (2014), Pereira et al. (2016). Este índice é definido como:

$$M = \frac{|\mu_b - \mu_u|}{\sigma_b + \sigma_u} \quad (3.1.5)$$

onde: μ_b e μ_u correspondem aos valores médios para as áreas queimadas e não queimadas, respectivamente, e σ_b e σ_u são os desvios-padrão correspondentes.

O índice de separação M foi utilizado para verificar se a média (μ_b) e o desvio padrão (σ_b) das áreas queimadas são estatisticamente distantes da média (μ_u) e do desvio padrão (σ_u) das áreas não queimadas. As mesmas diferenças observadas nas médias em cada índice representarão diferentes medidas de separabilidade de acordo com a distribuição dos valores nos histogramas. Os histogramas mais espalhados (maiores σ) causam maior sobreposição e menor capacidade de separabilidade do que os histogramas estreitos (menores σ) para a mesma diferença nas médias (KAUFMAN; REMER, 1994). Quanto maior a estatística M, melhor a discriminação entre áreas queimadas e áreas não queimadas (VERAVERBEKE et al., 2011). Um índice de separabilidade M maior do que um ($M > 1$) indica boa separação, enquanto um valor menor do que um ($M < 1$) revela uma capacidade discriminatória fraca (PEREIRA et al., 2016; KAUFMAN; REMER, 1994). Esta etapa foi essencial para definir qual índice espectral apresenta melhor capacidade em discriminar as áreas queimadas das áreas não queimadas e na identificação da área queimada núcleo por meio de um teste de limiar.

3.3.6. Testes de Limiares

Uma vez que este trabalho também pretende indicar o melhor limiar para a detecção de áreas queimadas, e seguindo as sugestões de Chuvieco et al. (2002), um teste de limiares, para o melhor índice espectral, foi realizado para identificar a área queimada, na qual apenas os pixels *core* dentro das cicatrizes de queimadas seriam discriminados (CHUVIECO et al., 2002; GARCIA; CHUVIECO, 2004). Para selecionar os limiares, o histograma do melhor índice espectral para a detecção de áreas queimadas foi dividido em duas regiões, com base em seus parâmetros estatísticos de média (μ) e desvio padrão (σ): uma cujos valores dos pixels estão mais concentrados e outra cujos valores de pixels estão mais espalhados. As regiões entre as distâncias de + 1,0; + 1,5; + 2,0; e - 1,0; - 1,5; - 2,0 dos desvios-padrão em relação à média (μ) foram utilizadas para os testes de limiares (+/- 1,0; +/- 1,5; +/- 2,0 σ). O melhor limiar identificado para cada AP e tipo de imagem foi então aplicado para a detecção de áreas queimadas.

3.3.7. Modelo Refinado de Detecção de Áreas Queimadas

Como última etapa da primeira fase da metodologia, um modelo baseado na abordagem de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) para refinar a detecção de áreas queimadas é proposta. Por meio de regras de decisão, as áreas queimadas, geradas na etapa anterior, foram refinadas, delimitando cada superfície queimada por um algoritmo de refinamento de forma (CHUVIECO et al., 2002; PINHO et al., 2012). Assim, o algoritmo de segmentação multi-resolução foi aplicado (BAATZ; SCHÄPE, 2000), uma máscara de água baseada nos dados de (NAMIKAWA et al., 2016), uma máscara de nuvem e sombra de nuvem gerada pelo algoritmo *Fmask* (*Function of Mask*) (ZHU; WOODCOCK, 2012; ZHU et al., 2015), a identificação de uma área mínima (com base na área mínima identificada nos dados de referência) e o uso combinado de diferentes índices espectrais para eliminar as confusões de detecção com outras coberturas da terra, diminuindo também os erros de omissão e comissão.

Primeiramente, foi aplicada a máscara de água e de nuvem para eliminar as possíveis áreas de confusão com estes alvos. Em seguida, foi selecionado um limiar de área mínima (0,36 ha), correspondente a áreas maiores que quatro pixels, para evitar a detecção de falsos positivos. Depois disso, para o processo de segmentação, o algoritmo de multi-resolução foi aplicado para o caso de melhor limiar (selecionado após a etapa

de teste de limiares) com a seguinte configuração: Escala: 10; Forma: 0,1; Compacidade: 0,5 para cada AP e tipo de imagem.

Para a seleção de objetos, a densidade de manchas queimadas em cada segmento foi calculada e os segmentos cujos valores foram maiores que 0,01 foram selecionados. Em seguida, um método de interseção utilizando um segundo índice espectral foi aplicado para confirmar as áreas queimadas em cada segmento. A seleção do segundo índice espectral baseou-se no ranque do índice M, de preferência cuja capacidade de discriminação das áreas queimadas fosse ótima ($M > 1$). Para a AP1 foi selecionado o índice espectral MIRBI e para a AP2 foi escolhido o índice NBR2. Finalmente, para a AP2, o NDVI para eliminar falsos positivos na cobertura florestal foi selecionado, uma vez que a maioria das áreas queimadas identificadas neste estudo apresenta resposta de sinal de queimada recente, que é diferente da queimada em floresta.

Além disso, com o objetivo de dar suporte à análise de detecção de áreas queimadas refinada, a distribuição do tamanho das manchas de áreas queimadas foi avaliado e a concordância espacial dos produtos de fogo ativo NOAA VIRRS-NPP (375m) (INPE, 2017) presentes no mapeamento de referência e no modelo refinado de detecção de áreas queimadas gerado foi quantificado.

3.4. Segunda Fase

A segunda fase da metodologia consiste no desenvolvimento de modelos de classificação baseado em técnicas de GEOBIA e Mineração de Dados para o mapeamento de áreas queimadas em três áreas de estudo (AP1, AP2 e AP3) e em três imagens de média resolução espacial (Landsat-8 OLI, Sentinel-2 MSI e CBERS-4 MUX). Entre as principais etapas desta segunda fase, inclui-se a segmentação, a extração de atributos, a seleção de atributos e a mineração dos dados. As etapas metodológicas da segunda fase são apresentadas a seguir.

3.4.1. Dados de Entrada

Os dados de entrada utilizados nesta segunda fase do trabalho basearam-se nos resultados obtidos na primeira fase. Desta forma, a definição dos melhores índices espectrais para a detecção de áreas queimadas nas AP1 e AP2 serviu como base para a composição (empilhamento de imagens) das camadas de dados de entrada. Como

critério para o desenvolvimento do modelo de classificação de áreas queimadas optou-se por selecionar as principais bandas espectrais de cada sensor e os principais índices espectrais de acordo com o resultado do índice M ($M > 1$), exceto para a AP3, devido a disponibilidade apenas de quatro bandas espectrais do sensor CBERS-4 MUX. A Tabela 3.6 resume os dados de entrada de cada AP utilizados nesta segunda fase da metodologia.

Tabela 3.6 - Dados de entrada de cada Área Piloto para a segunda fase da metodologia.

Camadas	Nome	AP1		AP2		AP3	
		OLI	MSI	OLI	MSI	OLI	MUX
Banda Azul	B1	✓	✓	✓	✓	✓	✓
Banda Verde	B2	✓	✓	✓	✓	✓	✓
Banda Vermelho	B3	✓	✓	✓	✓	✓	✓
Banda NIR	B4	✓	✓	✓	✓	✓	✓
Banda SWIR 1	B5	✓	✓	✓	✓	-	-
Banda SWIR 2	B6	✓	✓	✓	✓	-	-
BAI	B7	✓	✓	✓	✓	✓	✓
MIRBI	B8	✓	✓	✓	✓	-	-
SR	B9	-	-	✓	✓	✓	✓
NDVI	B10	-	-	✓	✓	✓	✓
SAVI	B11	-	-	✓	✓	✓	✓
EVI	B12	-	-	✓	✓	✓	✓
NBR1	B13	-	-	-	✓	-	-
NBR2	B14	-	-	✓	✓	-	-
CSI1	B15	-	-	-	✓	-	-
CSI2	B16	-	-	-	✓	-	-

Fonte: Produzido pelo autor.

3.4.2. Pré-processamento dos Dados de Entrada

A etapa de pré-processamento dos dados de entrada foi realizada no programa R Studio (R CORE TEAM, 2017), utilizando a linguagem de programação R, a fim de compatibilizá-los. Nesta etapa, todas as camadas com índices espectrais foram normalizadas e reescaladas para valores entre 0,0 e 1,0; de modo a possibilitar a

comparação entre índices, bem como evitar possíveis falsas interpretações no espaço de atributos. Para isto, a técnica de normalização de mínimos e máximos a 2% foi aplicada em cada camada índice com o intuito de realçar as feições das imagens, desta forma, redistribuindo os pixels das camadas índices de forma equalizada (YUAN, ELVIDGE, 1996).

As camadas índices normalizadas foram então importadas para a base de dados, juntamente as camadas multi-espectrais de cada sensor correspondente, para a realização dos procedimentos metodológicos que se sucedem nas próximas seções.

3.4.3. Segmentação

Após a seleção dos dados de entrada e do pré-processamento, as camadas de imagens foram importadas para a plataforma *eCognition* (TRIMBLE, 2014) e empilhadas em uma única imagem *stacking*, composta pelas bandas multi-espectrais de cada sensor mais as camadas índices calculadas para cada AP. Em seguida, foi executado o procedimento de segmentação de imagem utilizando o algoritmo de segmentação multi-resolução (BAATZ; SHÄPE, 2000).

Esta etapa é fundamental no fluxograma da GEOBIA e seus parâmetros são definidos segundo o conhecimento do especialista e ajustados empiricamente, de modo que os segmentos gerados representem da forma mais fiel possível os alvos e objetos presentes na imagem. O algoritmo de segmentação multi-resolução permite o ajuste de diversos parâmetros de entrada, como compacidade, suavidade, forma, cor, fator de escala e pesos diferenciados para cada uma das camadas da imagem *stacking*. Os valores ótimos para cada um desses parâmetros foram estimados de modo a representar da melhor maneira possível as áreas queimadas - obedecendo a uma dinâmica progressiva de testes de valores dos parâmetros de segmentação (APÊNDICE A). Para cada área de estudo e tipo de imagem, uma segmentação foi realizada. A Tabela 3.7 apresenta os melhores parâmetros obtidos neste estudo, conforme AP e sensor.

Tabela 3.7 - Valores ótimos estimados para os parâmetros de segmentação em cada área de estudo e tipo de imagem.

Áreas de Estudo	Escala	Critérios de Homogeneidade		Peso das Camadas																Número de Segmentos
		Forma	Compacidade	B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11	B12	B13	B14	B15	B16	
AP1 - OLI	30	0,7	0,5	1	1	1	1	1	1	2	2	-	-	-	-	-	-	-	-	69,012
AP1 - MSI	40	0,5	0,5	1	1	1	1	1	1	2	2	-	-	-	-	-	-	-	-	69,605
AP2 - OLI	30	0,4	0,5	1	1	1	1	1	1	2	2	1	1	1	1	-	2	-	-	81,518
AP2 - MSI	30	0,3	0,5	1	1	1	1	1	1	2	2	1	1	1	1	2	2	1	1	64,661
AP3 - OLI	30	0,4	0,5	1	1	1	1	-	-	2	-	1	1	1	1	-	-	-	-	61,955
AP3 - MUX	10	0,1	0,5	1	1	1	1	-	-	2	-	1	1	1	1	-	-	-	-	32,075



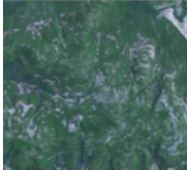



Fonte: Produzido pelo autor.

3.4.4. Tipologia e Definição das Classes

A definição das classes para a detecção de áreas queimadas foi dividida em duas categorias: Superclasses e Subclasses. No primeiro nível de abstração de classes presentes nas imagens (Superclasses), optou-se por agrupar as diferentes feições das imagens em duas superclasses: Áreas Queimadas e Áreas Não Queimadas. No segundo nível de abstração de classes, sete subclasses foram identificadas nas imagens das APs e categorizadas segundo a legenda proposta pelo Projeto MapBiomias (MAPBIOMAS, 2017). Na Tabela 3.8, são apresentadas as duas categorias de classes, as tipologias das classes e a descrição das mesmas.

Os experimentos desta segunda fase da metodologia foram executados apenas para o primeiro nível de abstração de classes, desta forma, optando-se por diferenciar e caracterizar os principais atributos descritores das *Áreas Queimadas* em relação ao restante das feições presentes nas imagens, agrupadas na superclasse *Áreas Não Queimadas*.

Tabela 3.8 - Definição das tipologias de classes presentes nas imagens.

Superclasses	Subclasses	Tipologia	Descrição
Áreas Queimadas	Áreas Queimadas		Áreas caracterizadas por queimadas recentes com exposição de solo carbonizado em diferentes estágios.
	Floresta		Categoria que inclui tipos de vegetação composta por árvores altas com predomínio de dossel contínuo podendo ser ombrófila, decidual, semi-decidual ou estacional. Além de árvores médias e de pequeno porte com estrato arbusto-herbáceo. Esta categoria inclui também áreas de mangue e silvicultura.
Áreas Não Queimadas	Formações Naturais Não Florestais		Formações campestres com predominância de estrato herbáceo-arbustivo, herbáceo-arbóreo e herbáceo-lenhoso, podendo ou não, serem encontradas em áreas úmidas de planície, sujeitas a inundações periódicas ou permanentes.
	Uso Agropecuário		Áreas utilizadas pela atividade agropecuária, inclui áreas de agricultura (cultivos permanente, perene e semi-perene) e pastagem (naturais ou plantadas e com atividade pecuária).
	Áreas Não Vegetadas		Classe mista que inclui áreas agrícolas em preparo, solo exposto, afloramentos rochosos, superfícies arenosas e áreas de infraestrutura urbana.
	Corpos D'Água		Massas de água superficiais que podem ser contínuas (ex. rios e lagos) ou isoladas (ex. áreas alagadas e açudes).
	Nuvem/Sombra de Nuvem		Feições identificadas na imagem como nuvem ou sombra de nuvem.

Fonte: Produzido pelo autor.

3.4.5. Extração de Atributos

Nesta etapa, diversos atributos foram extraídos: customizados, espectrais e espaciais. Os atributos de cada segmento foram calculados sobre a imagem *stacking* com base nos próprios valores de nível de cinza, bem como, os atributos espaciais (incluindo atributos de forma, geometria e de textura), possíveis de serem extraídos na abordagem baseada em objetos.

Optou-se nesta etapa por explorar ao máximo os diversos atributos disponíveis na plataforma *eCognition*, analisando qualitativamente os atributos que poderiam ser extraídos e relevantes para a caracterização das áreas queimadas. Alguns desses atributos são apresentados na Tabela 3.9.

Um total de 47 atributos, subdivididos em 4 categorias foram calculados para cada imagem *stacking*: 17 atributos espectrais, 1 atributo customizado, 21 atributos de forma/geométricos e 8 atributos de textura. Alguns destes atributos em determinadas categorias (*e.g.* média, moda e desvio padrão) são calculados para cada camada da imagem *stacking*; nestes casos, o número total de atributos gerados é maior que os 47 atributos iniciais esperados, acarretando em um volume de dados considerável a ser minerado pelos algoritmos.

Tabela 3.9 - Alguns atributos espectrais e espaciais da abordagem baseada em objetos.

Atributo	Descrição	Tipo
<i>Mean</i> (Média)	Retorna o valor médio de todos os N pixels dentro do objeto.	Espectral
<i>Mode</i> (Moda)	Retorna o valor mais ocorrido (moda) para todos os N pixels dentro do objeto.	Espectral
<i>Standard Deviation</i> (Desvio Padrão)	Retorna o desvio padrão de todos os N pixels dentro do objeto.	Espectral
<i>Quantile</i> (Quartil)	Retorna o Quartil 50% de todos os N pixels dentro do objeto.	Espectral
<i>Area</i> (Área)	Retorna a área do objeto. Quando medido em pixels é igual a N .	Espacial Geométrico
<i>Width</i> (Largura)	É a largura da borda do objeto.	Espacial Geométrico
<i>Length</i> (Comprimento)	É o comprimento da caixa delimitadora do objeto.	Espacial Geométrico
<i>Asymmetry</i> (Assimetria)	Mede o quão irregular é o objeto em questão.	Espacial de Forma
<i>Roundness</i> (Circularidade)	Mede o enquadramento da forma do segmento em relação a um círculo traçado ao seu redor.	Espacial de Forma
<i>Compactness</i> (Compacidade)	Descreve o quão compacto um objeto é, causando a impressão de uma pequena borda capaz de comportar todo volume do objeto.	Espacial de Forma
<i>Density</i> (Densidade)	Representa a distribuição dos pixels no espaço dentro do segmento.	Espacial de Forma
<i>Elliptic Fit</i> (Enquadramento Elíptico)	Representa o quanto um segmento se aproxima de uma forma elíptica perfeita.	Espacial de Forma
<i>Border Index</i> (Índice de Borda)	Descreve o quão irregular é a forma de uma borda de um segmento.	Espacial de Forma
<i>Shape Index</i> (Índice de Forma)	Uma relação de área/perímetro que descreve a suavidade de uma borda de um segmento.	Espacial de Forma
<i>GLCM Homogeneity</i>	Retorna o valor de homogeneidade da matriz de coocorrência de níveis de cinza (GLCM)	Espacial de Textura
<i>GLCM Contrast</i>	Retorna o valor de contraste da matriz de coocorrência de níveis de cinza (GLCM)	Espacial de Textura
<i>GLCM Entropy</i>	Retorna o valor de entropia da matriz de coocorrência de níveis de cinza (GLCM)	Espacial de Textura
<i>GLCM Correlation</i>	Retorna o valor de correlação da matriz de coocorrência de níveis de cinza (GLCM)	Espacial de Textura
Transformação IHS (Intensidade)	Este atributo derivado da transformação IHS foi calculado para a combinação entre as bandas (SWIR1,NIR,Red) na componente Intensidade (<i>Intensity</i>)	Customizado

Fonte: Adaptado de Haralick et al. (1973); Körting (2012); França (2017); Neves (2017).

3.4.6. Seleção de Atributos

Após a extração dos atributos, a etapa de seleção de atributos foi executada com o intuito de diminuir o conjunto de dados – para evitar a redundância de informações - e selecionar apenas os atributos mais relevantes para a detecção de áreas queimadas. Este procedimento foi realizado na plataforma *WEKA (Waikato Environment for Knowledge Analysis)* (HALL et al., 2009) utilizando o método de Seleção Baseada em Correlação (do inglês *Correlation Feature Selection - CFS*).

Este método proposto por Hall (1999) baseia-se em um algoritmo de filtro simples que classifica subconjuntos de atributos de acordo com uma correlação baseada em uma função de avaliação heurística. Deste modo, o algoritmo avalia se os subconjuntos apresentam atributos altamente correlacionados com as classes e não são correlacionados entre si, ou seja, atributos muito correlacionados serão ignorados pelo algoritmo - evitando assim a redundância de informações.

Segundo Neves (2017) que aplicou o mesmo método para áreas de pastagens na Amazônia, o método CFS além de se basear na correlação dos atributos com as classes, é independente do algoritmo de classificação. O CFS não gera um ranking de atributos, mas escolhe um conjunto S (*Best First*) de k atributos com maior mérito. A função de avaliação CFS é expressa segundo a Equação 3.2.6. O numerador da equação indica o poder preditivo do conjunto, enquanto o denominador indica o grau de redundância existente entre os atributos (HALL, 1999).

$$M_S = \frac{k * r'_{ac}}{\sqrt{k + k(k - 1)r'_{aa}}} \quad (3.4.6)$$

Onde: M_S é o mérito do subconjunto de atributos S contendo k atributos, r'_{ac} corresponde à média da correlação entre atributo-classe e r'_{aa} corresponde à média da correlação entre atributo-atributo.

3.4.7. Mineração de Dados

Após a etapa de extração e seleção de atributos do conjunto de dados, a etapa de mineração dos dados foi executada. O objetivo da mineração de dados é o reconhecimento de padrões para a classificação de *Áreas Queimadas* e *Áreas Não*

Queimadas. Optou-se nesta etapa por utilizar um algoritmo de árvore de decisão, devido à possibilidade de fácil compreensão do conjunto de regras criadas pelo algoritmo para construção do modelo de classificação, além de permitir a identificação dos atributos descritores mais relevantes para a classificação de áreas queimadas. A construção de árvores de decisão não requer nenhum conhecimento ou domínio prévio dos parâmetros de configuração, apresentando-se, portanto, como vantajoso e apropriado para descoberta de conhecimento exploratório (HAN et al., 2012).

Além disso, a árvore de decisão pode selecionar automaticamente os atributos apropriados que separam iterativamente o conjunto de dados em grupos menores de acordo com os diferentes valores desses atributos e em regras de decisão (HAN et al., 2012). A árvore de decisão é uma estrutura de árvore semelhante a um diagrama que consiste em uma coleção de nós de decisão, conectados por ramos, que se estendem para baixo a partir do nó raiz até terminar em nós de folha. Um nó interno (nó de decisão) denota um teste de atributo, um ramo da árvore que representa o resultado do teste de atributo e o nó de folha que é o fim de um ramo da árvore representa o rótulo da classe identificada (HAN et al., 2012; LAROSE; LAROSE, 2014).

O algoritmo de classificação utilizado nesta etapa foi o C4.5 (QUINLAN, 1993), implementado na plataforma *WEKA* como J48. Este algoritmo é um dos classificadores supervisionados mais utilizados na mineração de dados (WU et al., 2008), no qual amostras das classes de interesse são necessárias para o treinamento e aprendizagem do algoritmo. O algoritmo C4.5 visita recursivamente cada nó de decisão, selecionando a divisão ideal, até que nenhuma divisão adicional seja possível, o que pode resultar em árvores de tamanhos variáveis. Além disso, por padrão, este método produz um ramo separado para cada valor do atributo categórico o que pode acarretar no surgimento de “arbustos” indesejáveis, uma vez que alguns valores podem ter baixa frequência ou podem, naturalmente, ser associados a outros valores (LAROSE; LAROSE, 2014).

Ma et al. (2017), realizaram uma revisão bibliográfica e não observaram diferenças significativas na utilização de diferentes classificadores (*e.g.* C4.5, CART, RF, SVM, KNN) em termos de exatidão global (em média superiores a 80%). Embora o algoritmo C4.5 crie árvores com tamanhos variáveis, visto que é uma característica inerente ao método, o mesmo se apresenta como um classificador robusto para que os objetivos deste estudo sejam alcançados.

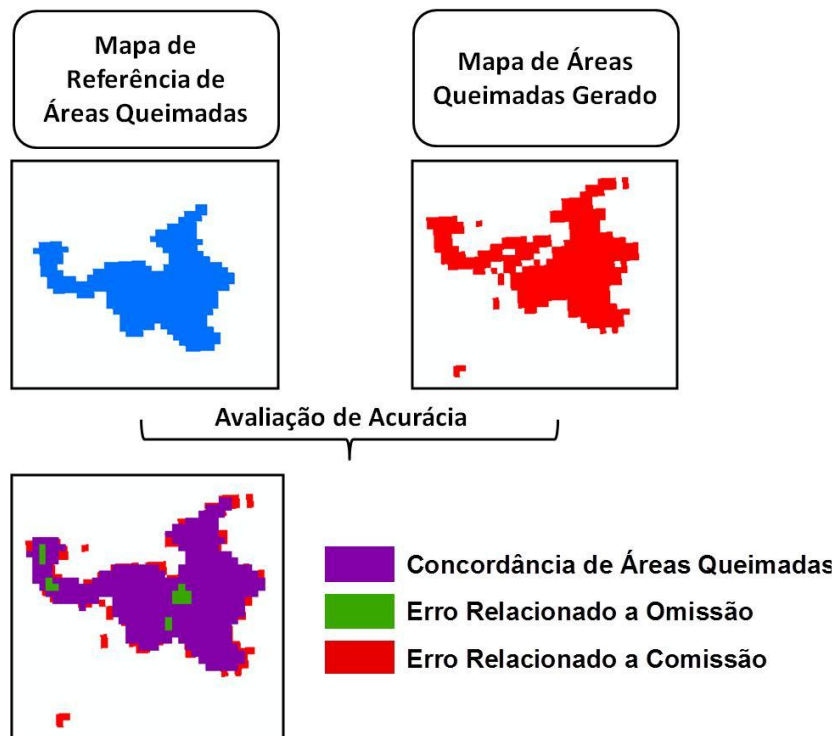
As amostras para o treinamento dos modelos de classificação foram coletadas a partir dos objetos (gerados na etapa de Segmentação) e dos atributos extraídos sobre estes - considerando também a correlação espacial dos objetos com as máscaras de *Áreas Queimadas* e *Áreas Não Queimadas* dos dados de referência. Desta forma, construindo modelos de classificação baseados em GEOBIA e na mineração de dados para cada Área Piloto e tipo de imagem.

3.4.8. Avaliação da Exatidão dos Produtos de Áreas Queimadas

A etapa de avaliação da exatidão dos produtos gerados de áreas queimadas buscou verificar a acurácia da detecção de áreas queimadas em relação aos dados de referência (verificar Seção 3.1.3) e foi realizada nas duas fases da metodologia. Na primeira fase, a avaliação foi realizada nas etapas de teste de limiares e de filtragem empírica. Na segunda fase, a avaliação foi realizada ao término da etapa de mineração de dados.

O processo de avaliação da exatidão foi baseado nas metodologias de Congalton (2001), Congalton e Green (2009), Oliva e Schroeder (2015) (Figura 3.8) que consistiu na intersecção dos dados de referência com as áreas estimadas pela metodologia e na geração de matrizes de confusão. A Concordância de Áreas Queimadas é considerada como a coincidência espacial entre as manchas de áreas queimadas estimadas e as áreas queimadas dos dados de referência. O Erro Relacionado à Omissão se refere às áreas que não foram classificadas pela metodologia proposta como áreas queimadas enquanto o Erro Relacionado a Comissão descreve as áreas que não foram classificadas corretamente como áreas queimadas.(OLIVA; SCHROEDER, 2015).

Figura 3.8 - Modelo de avaliação de exatidão das áreas queimadas.



Fonte: Adaptado de Oliva e Schroeder (2015).

Com intuito de avaliar quantitativamente os resultados obtidos e seguindo as recomendações de Padilla et al. (2015) e Padilla et al. (2017), também foram calculados a partir da matriz de confusão (Tabela 3.10): (a) Exatidão Global - representa a relação entre o número de amostras classificadas corretamente sobre o número total de amostras de referência; (b) Acurácia do Produtor - relativo aos Erros de Omissão (E_o) - representa a relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras de referência da classe k ; (c) Acurácia do Usuário - relativo aos Erros de Comissão (E_c), corresponde à relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras classificadas da classe k ; (d) Coeficiente *Dice* (do inglês *Dice Coefficient* – DC) e; (e) Erro Relativo (do inglês *Relative Bias* – RelB) para suportar todas as análises.

As métricas DC e RelB têm sido amplamente aplicadas em estudos de mapeamento de áreas queimadas desde que Padilla et al. (2015) obteve maior precisão na avaliação da categoria *Áreas Queimadas* bem como dos erros relativos associados (RelB). Deste modo, rompendo com os métodos tradicionais de avaliação de exatidão de mapeamentos, tal como o índice Kappa, conforme já apontado previamente por (PONTIUS JR.; MILLONES, 2011).

Tabela 3.10 - Modelo de matriz de confusão.

		Referência			
		Queimada	Não Queimada	...	Total
Classificação	Queimada	E_{11}	E_{12}	...	$1 + E_{1+}$
	Não Queimada	E_{21}	E_{22}	...	$2 + E_{2+}$

	Total	E_{+1}	E_{+2}	...	n

Fonte: Adaptado de Padilla et al. (2015)

O DC (DICE, 1945) combina os erros de omissão e comissão em uma única métrica, o que é útil para verificar as precisões do mapeamento, bem como é uma medida sumária de precisão da categoria *Áreas Queimadas* (PADILLA et al., 2015; PADILLA et al., 2017). DC é expresso segundo a Equação 3.3.1:

$$DC = \frac{2 E_{11}}{2(E_{11} + E_{12} + E_{21})} \quad (3.4.8.1)$$

onde E_{11} é o número de verdadeiros positivos, E_{12} é o número de falsos positivos e E_{21} é o número de falsos negativos na matriz de confusão. Esse índice varia de 0 a 1, no qual valores próximos a 0 podem ser considerados ruins e próximos a 1 com boa exatidão.

O RelB (Equação 3.3.2) é uma medida de erros em relação às áreas queimadas de referência e expressa aos usuários finais o balanceamento de erro relativo do produto de áreas queimadas gerado (MOUILLOT et al., 2014; PADILLA et al., 2015; PADILLA et al., 2017).

$$RelB = \frac{E_{12} - E_{21}}{E_{+1}} \quad (3.4.8.2)$$

onde E_{+1} é o número total de elementos no dado de referência. Os valores de RelB indicam se um produto superestima (sinal positivo) ou subestima a extensão das áreas queimadas (sinal negativo) (PADILLA et al., 2015).

4 RESULTADOS E DISCUSSÃO

Neste capítulo, os principais resultados do trabalho são apresentados. Para que a leitura desta Seção seja mais fluida, alguns resultados foram colocados nos Apêndices. As Seções 4.1, 4.2 e 4.3 buscam responder o objetivo específico I. A Seção 4.4 visa cumprir os objetivos III e IV. Já as Seções 4.5, 4.6 e 4.7 atendem aos objetivos específicos II e III. Por fim, a Seção 4.8 suscita as discussões propostas no objetivo IV.

4.1. Avaliação dos Índices Espectrais


Nesta Seção, a análise da separabilidade dos índices espectrais foi realizada por meio de *boxplot*. Os índices analisados são aqueles apresentados na Seção 3.1.4 (Tabela 3.5).

Os gráficos do tipo *boxplot*, para as áreas de estudo AP1 e AP2 e imagens (Landsat-8 OLI e Sentinel-2 MSI) são apresentados nas Figuras 4.1 e 4.2. Os *boxplots* foram normalizados para valores na faixa [0, 1], para facilitar a comparação da separabilidade dos índices. Os *boxplots* em laranja representam os valores de áreas queimadas e *boxplots* em azul representam os valores das áreas não queimadas para cada índice. A linha central representa as medianas, enquanto a amplitude interquartilica representa 50% dos valores, ou os valores do segundo e terceiro quartis. As linhas representam os valores máximos não discrepantes, enquanto os pontos são valores discrepantes.


De forma geral, a análise dos gráficos *boxplot* mostra que a sobreposição dos valores dos índices de áreas queimadas e não queimadas, que indica correlação, é maior na área AP1 (Figura 4.1) do que na área AP2 (Figura 4.2). Ou seja, a maioria dos índices espectrais, para a AP2, é capaz de discriminar as classes.

Os gráficos *boxplot* dos índices, gerados a partir das imagens Landsat-8 OLI, apresentam menor espalhamento do que os índices gerados pelas imagens do Sentinel-2 MSI. Desta maneira, o menor intervalo de valores (menor espalhamento) facilita a discriminação entre as classes.

Figura 4.1- *Boxplots* dos índices espectrais normalizados para API: (A) *Boxplots* para imagem Landsat-8 OLI; (B) *Boxplots* para imagem Sentinel-2 MSI.



(A)




(B)


■ Áreas Queimadas ■ Áreas Não Queimadas

Fonte: Produzido pelo autor.

Figura 4.2 - *Boxplots* dos índices espectrais normalizados para AP2: (A) *Boxplots* para imagem Landsat-8 OLI; (B) *Boxplots* para imagem Sentinel-2 MSI.



(A)



(B)

■ Áreas Queimadas ■ Áreas Não Queimadas

Fonte: Produzido pelo autor.

4.2. Ranking dos Índices Espectrais

A análise estatística dos 12 índices espectrais contribuiu para a discussão sobre a não correlação entre áreas queimadas e não queimadas. De acordo com o teste U de *Mann-Whitney* (Verificar a Seção 3.1.5), assumindo o valor de significância de 5%, os resultados estatísticos para cada índice apresentaram p-valor inferior a 0,05 (p-valor = $2,2e^{-16}$). Desta forma, a hipótese nula é rejeitada e a hipótese alternativa é aceita, ou seja, a distribuição de valores de cada índice espectral apresenta diferença significativa entre áreas queimadas e não queimadas. Este resultado indica que as classes não estão correlacionadas e podem ser separadas por limiares.

Para ranquear os melhores índices espectrais, o índice de separabilidade M para cada índice espectral foi calculado, como mostra a Tabela 4.1. Conforme apresentada na Seção 3.1.5, a estatística M mede a sobreposição da frequência de valores de um histograma de um objeto de interesse em relação ao histograma de outros objetos, apresentando assim o grau de separabilidade entre as classes (PEREIRA et al., 2016). Para AP1 (Figura 4.3) apenas os índices BAI e MIRBI indicaram boa separabilidade ($M > 1$) tanto para a imagem Landsat-8 OLI como para a imagem Sentinel-2 MSI. Os outros índices foram considerados de baixa separabilidade ($M < 1$). Para a AP2 (Figura 4.4), sete índices gerados a partir das imagens Landsat-8 OLI e dez índices gerados a partir de imagens Sentinel-2 MSI foram considerados apropriados ($M > 1$). As diferenças nos valores de M, para as duas áreas de estudo, podem ser explicadas pela heterogeneidade das diferentes coberturas da terra e devido à presença de outros alvos com baixa reflectância nas imagens.

Para a AP1, as pastagens e áreas de solo exposto, que apresentam baixa resposta espectral, possivelmente, foram sensíveis a maioria dos índices analisados. Por outro lado, na AP2, a principal cobertura da terra é floresta, o que explica os índices de vegetação apresentarem maior separabilidade, assim como a maior parte dos índices de queimada (baixos erros de detecção). Segundo Pereira (1999), as diferenças de desempenho dos índices espectrais para a discriminação das áreas queimadas ocorrem devido ao período entre a aquisição de dados e a ocorrência das queimadas. Além disso, os índices são afetados pelas características específicas dos diferentes biomas estudados que afetam também as propriedades espectrais das queimadas.

Observou-se também na Tabela 4.1 que, de acordo com o índice M, o BAI ($M > 1,5$) foi considerado o melhor índice espectral para todos os tipos de imagens. Segundo Chuvieco et al. (2002), o índice BAI foi projetado para realçar a resposta espectral de alvos carbonizados em imagens pós-fogo. Essa resposta espectral de áreas queimadas se confunde com a dos alvos de baixa reflectância, tais como corpos d'água e sombras de nuvens, conforme encontrado nos resultados do presente estudo tanto para AP1 quanto AP2.

Para a Amazônia, há uma lacuna de estudos de avaliação de índices espectrais para a detecção de áreas queimadas. No entanto, para o Cerrado, alguns estudos obtiveram bons resultados com a aplicação de índices espectrais para a discriminação de áreas queimadas, destacando-se os índices MIRBI, NBR2 e NDVI para imagens Landsat TM, e também considerando uma abordagem bi-temporal (ocorrência pré e pós-fogo) (MELCHIORI et al., 2015; PEREIRA et al., 2016). Pereira (1999), Libonati et al. (2012) e Pereira et al. (2016) recomendam o uso de índices espectrais que incluem na sua formulação faixas do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR) para a detecção de áreas queimadas.

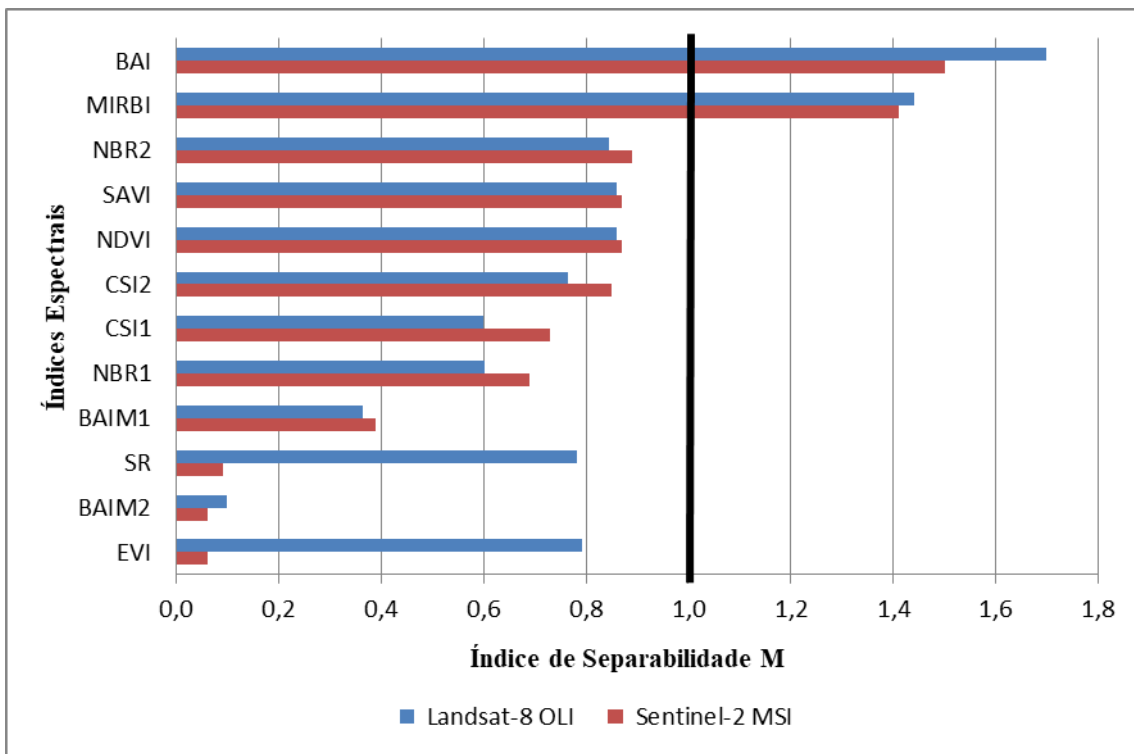
Neste estudo, os resultados indicam que o BAI apresenta boa separabilidade. Isto pode ser explicado devido à abordagem com data fixa, que favorece os índices espectrais com maior sensibilidade espectral às áreas queimadas recentes cuja resposta espectral é similar às áreas carbonizadas. Nesse sentido, embora este índice tenha sido desenvolvido conceitualmente para regiões do Mediterrâneo, ele foi projetado para discriminar áreas queimadas na faixa espectral do NIR (CHUVIECO et al., 2002). Por outro lado, o índice BAIM apresentou os piores resultados ($M < 0,5$) para a discriminação de áreas queimadas, devido aos seus coeficientes específicos que foram desenvolvidos para uma região particular de estudo.

Tabela 4.1 - Índice de separabilidade M para os índices espectrais e classificação dos melhores índices em cada AP.

Índice de Separabilidade M – AP1				Índice de Separabilidade M – AP2			
Landsat-8 OLI		Sentinel-2 MSI		Landsat-8 OLI		Sentinel-2 MSI	
Ranking Índices	Valores M	Ranking Índices	Valores M	Ranking Índices	Valores M	Ranking Índices	Valores M
BAI	1,7073	BAI	1,5001	BAI	1,6484	BAI	1,6168
MIRBI	1,4435	MIRBI	1,4127	SAVI	1,4108	NBR2	1,4406
SAVI	0,8595	NBR2	0,8935	SR	1,3961	CSI2	1,3973
NDVI	0,8594	SAVI	0,8791	NDVI	1,3948	EVI	1,3633
NBR2	0,8438	NDVI	0,8790	NBR2	1,3732	SAVI	1,3133
EVI	0,7930	CSI2	0,8569	EVI	1,1311	NDVI	1,3131
SR	0,7828	CSI1	0,7338	MIRBI	1,0603	SR	1,3070
CSI2	0,7651	NBR1	0,6940	NBR1	0,9607	NBR1	1,2719
NBR1	0,6013	BAIM1	0,3927	CSI2	0,7683	MIRBI	1,2330
CSI1	0,5989	SR	0,0989	BAIM2	0,5051	CSI1	1,1961
BAIM1	0,3651	BAIM2	0,0645	CSI1	0,3828	BAIM2	0,5582
BAIM2	0,0981	EVI	0,0621	BAIM1	0,1928	BAIM1	0,1168

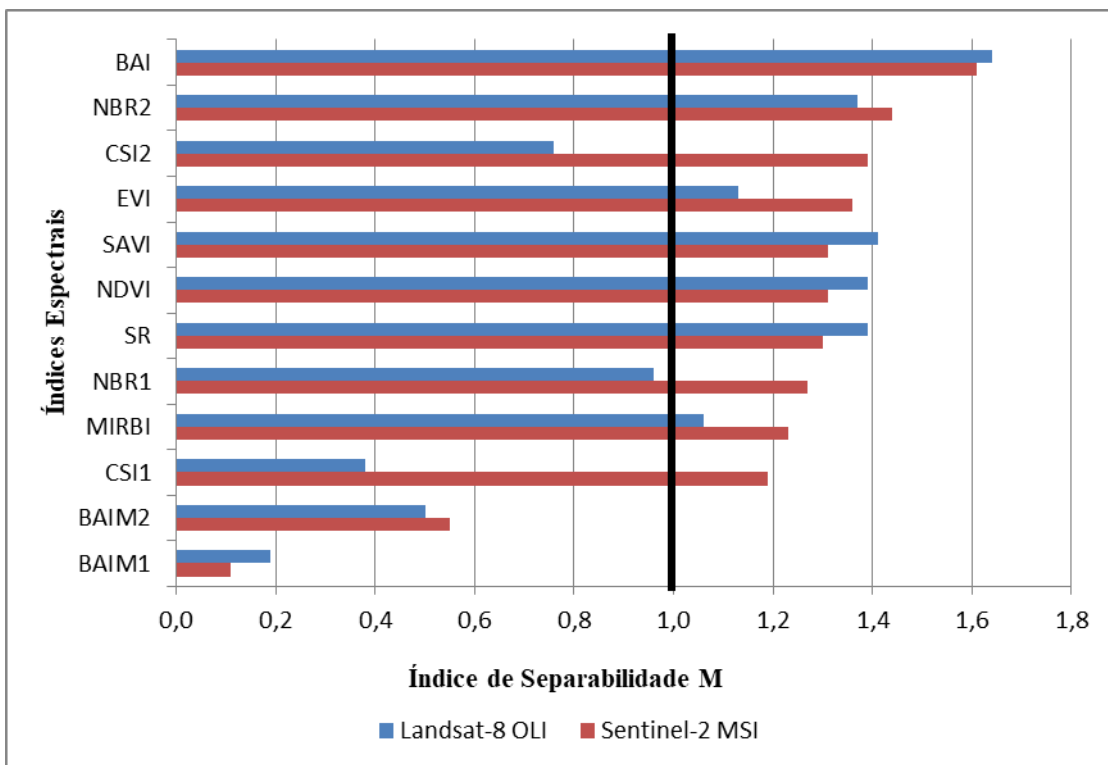
Fonte: Produzido pelo autor.

Figura 4.3 - Resultado do Índice de separabilidade M para todos os índices espectrais na AP1.



Fonte: Produzido pelo autor.

Figura 4.4 - Resultado do Índice de separabilidade M para todos os índices espectrais na AP2.

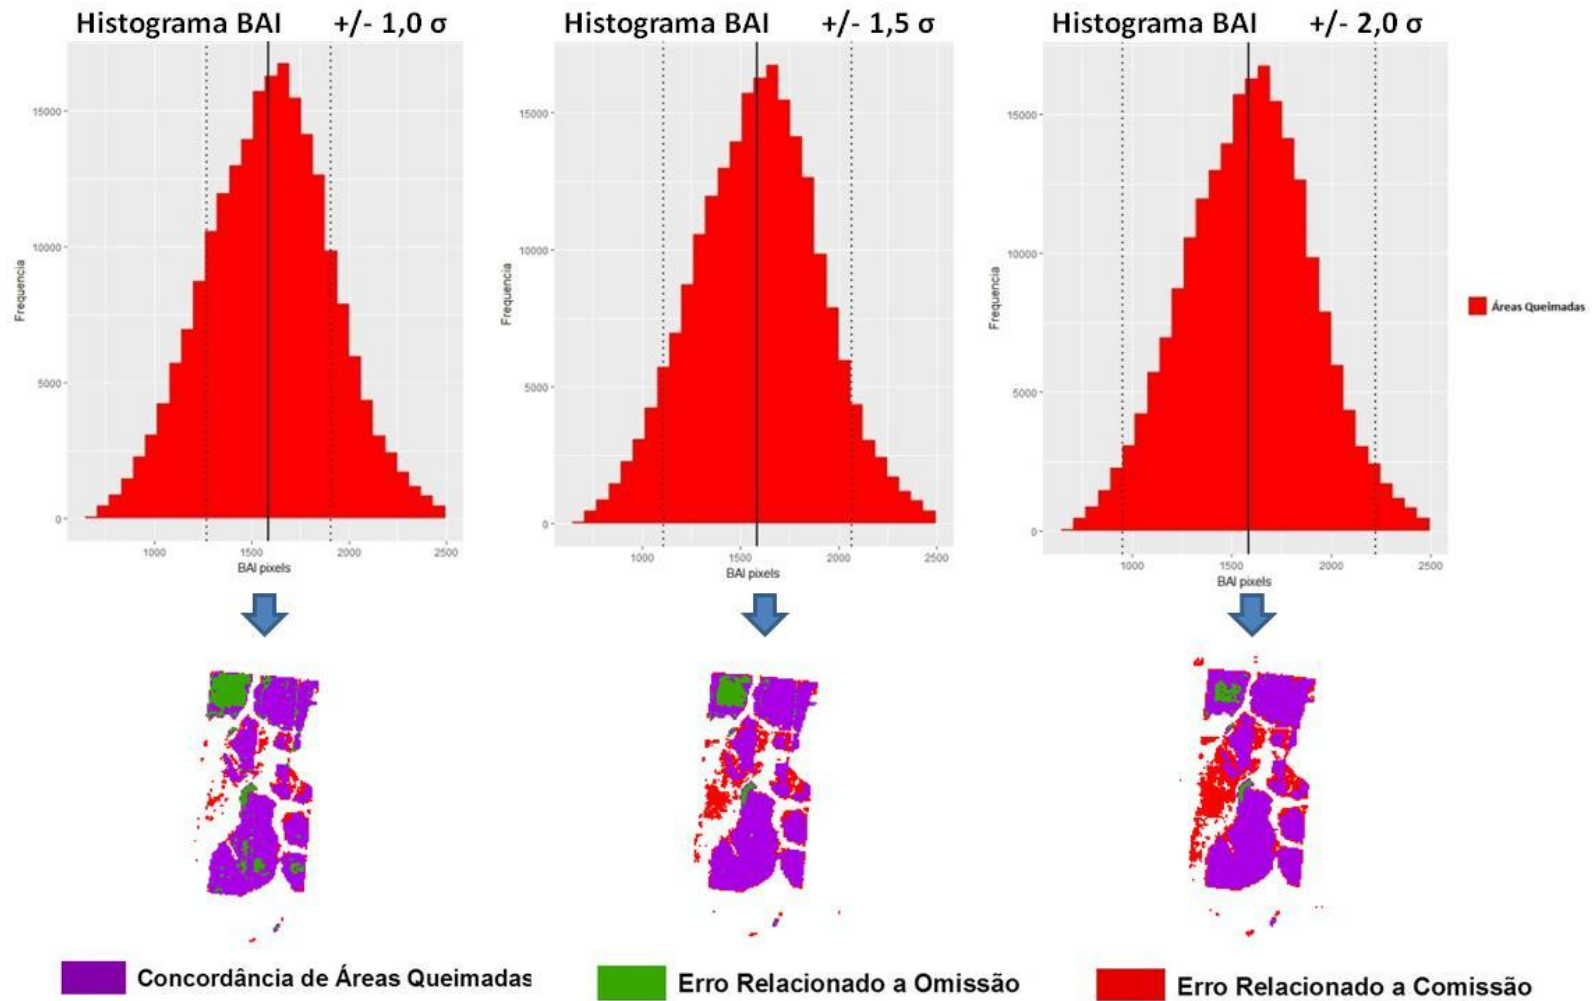


Fonte: Produzido pelo autor.

4.3. Resultados dos Testes de Limiares

Após o ranqueamento dos índices espectrais, os testes de limiares para identificar áreas queimadas foram realizados apenas para o índice BAI porque este apresentou os melhores resultados estatísticos na etapa anterior. Os limiares de $\pm 1,0 \sigma$; $\pm 1,5 \sigma$; $\pm 2,0 \sigma$ sobre os histogramas de áreas queimadas do índice BAI foram testados, mapeados e posteriormente avaliados. Para cada área de estudo e tipo de imagem, o desvio padrão $\pm 2,0 \sigma$ foi selecionado como o limiar mais adequado para representar as áreas queimadas (Figura 4.5). Este limiar inclui a maioria das áreas queimadas e não omite informações relevantes. No entanto, se adotarmos apenas esse limiar para o mapeamento da área queimada, várias manchas pequenas, que não representam áreas queimadas (falso positivo), são detectadas. Neste caso, é necessária uma etapa de pós-processamento. Apesar do limiar $\pm 2,0 \sigma$ aumentar os erros de comissão, ele foi o melhor para evitar a não inclusão de manchas de áreas queimadas. Em outras palavras, este limiar permite a identificação de regiões homogêneas de áreas queimadas com o menor erro de omissão.

Figura 4.5 - Histogramas do índice espectral BAI para AP1 e imagem Landsat-8 OLI de acordo com as três limiares testados.



Fonte: Produzido pelo autor.

Com o intuito de verificar o melhor limiar do índice BAI em cada AP e tipo de imagem, a avaliação de exatidão dos limiares foi realizada, gerando uma matriz de confusão para cada limiar. Estes resultados são apresentados no APÊNDICE B. Para definir o melhor limiar do índice BAI, os Erros de Omissão (Eo), Erros de Comissão (Ec), Coeficiente Dice (DC) e o Erro Relativo (RelB), apresentados na Tabela 4.2, foram calculados.

O limiar $\pm 2,0 \sigma$ foi escolhido como o mais adequado na discriminação de áreas queimadas devido aos baixos erros de omissão apresentados (cerca de 35% menor em relação à média dos Erros de Omissão) em relação aos outros limiares. Entretanto, os erros de comissão aumentam (cerca de 20% em relação à média dos Erros de Comissão) em comparação aos limiares $\pm 1,0 \sigma$ e $\pm 1,5 \sigma$. O DC e RelB tendem a diminuir conforme aumenta o valor do limiar, embora a exatidão global ainda permaneça alta (valores entre 93% e 96%, ver APÊNDICE B.3). Além disso, se considerarmos a área total mapeada pelo limiar $\pm 2,0 \sigma$ observamos uma superestimação das áreas queimadas da ordem de 135% a 185% e 528% a 552%, respectivamente para as áreas AP1 e AP2. Esta superestimação pode ser explicada pelos erros de detecção, especialmente na AP2, onde a maior parte das áreas queimadas ocorre próximo de florestas e o pequeno tamanho das áreas queimadas prejudica a detecção correta quando um limiar fixo é usado.

As áreas não queimadas são consideradas como heterogêneas em relação às áreas queimadas, uma vez que elas incluem coberturas da terra, como bordas de lagos, sombras topográficas e áreas misturadas com vegetação urbana. Além de nuvens e sombras de nuvens, que apresentam potenciais confusões com as áreas queimadas (CHUVIECO; CONGALTON, 1988; BASTARRIKA et al., 2011). Assim, é mais viável identificar esses alvos na imagem e minimizar os erros de confusão por um processo de filtragem e a construção de um modelo de detecção de áreas queimadas baseado em GEOBIA.

Tabela 4.2 - Erros de Omissão (Eo), Erros de Comissão (Ec), Coeficiente Dice (DC) e o Erro Relativo (RelB) calculados para os testes de limiares.

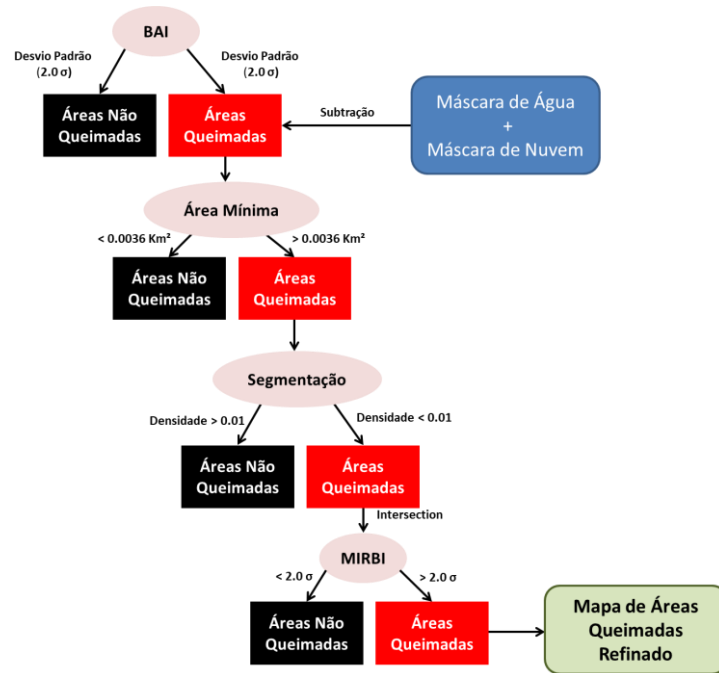
		AP1							
		Landsat-8 OLI				Sentinel-2 MSI			
		Eo	Ec	DC	RelB	Eo	Ec	DC	RelB
Limiares	+/-1,0	0,34	0,27	0,69	47,70	0,33	0,71	0,40	308,05
	+/-1,5	0,16	0,46	0,66	138,09	0,23	0,72	0,41	369,51
	+/-2,0	0,07	0,67	0,48	373,34	0,15	0,75	0,39	469,02
Média		0,19	0,47	0,61	186,37	0,24	0,73	0,40	382,19
		AP2							
		Landsat-8 OLI				Sentinel-2 MSI			
		Eo	Ec	DC	RelB	Eo	Ec	DC	RelB
Limiares	+/-1,0	0,34	0,73	0,38	176,66	0,34	0,42	0,61	47,66
	+/-1,5	0,15	0,76	0,38	264,85	0,15	0,62	0,53	137,85
	+/-2,0	0,05	0,88	0,21	687,95	0,06	0,86	0,24	575,94
Média		0,18	0,79	0,32	376,49	0,18	0,63	0,46	253,81

Fonte: Produzido pelo autor.

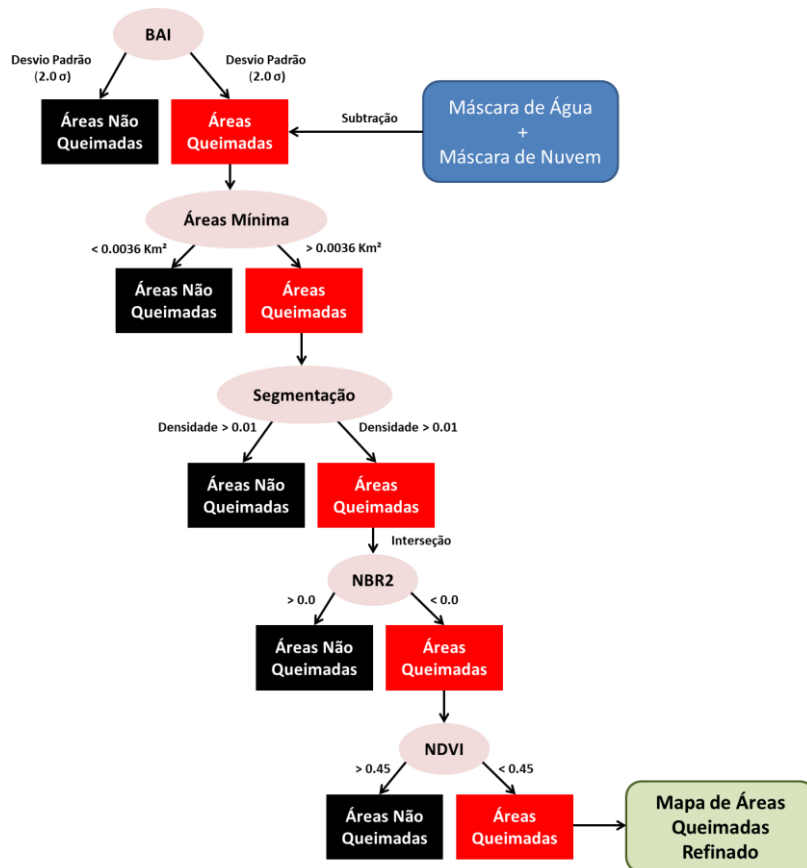
4.4. Resultados do Modelo de Detecção de Áreas Queimadas

Para melhorar o processo de detecção de áreas queimadas, um modelo empírico, baseado em GEOBIA e em regras de decisão foi desenvolvido. Este processo inclui uma máscara de água, uma máscara de nuvem gerada pelo algoritmo *Fmask*, a identificação de uma área mínima, o uso de um método de segmentação e o uso combinado de outros índices espectrais (MIRBI, NDVI, NBR2) para eliminar a confusão da classe *Áreas Queimadas* com outras coberturas da terra, tais como pastagem e floresta. Para cada área de estudo, um modelo de filtragem para refinar o processo de detecção de áreas queimadas foi desenvolvido, conforme o conjunto de regras descrito na Seção 3.1.7. O modelo de filtragem é apresentado na Figura 4.6.

Figura 4.6 - Modelo de filtragem empírica para refinar a detecção de áreas queimadas usando o índice BAI para as áreas de estudo AP1 (A) e AP2 (B).



(A)



(B)

Fonte: Produzido pelo autor.

Os mapas de áreas queimadas derivados do BAI refinado são apresentados nas Figuras 4.7 e 4.8, respectivamente, para as áreas de estudo AP1 e AP2. Os resultados da avaliação de exatidão dos mapas refinados de áreas queimadas são apresentados na Tabela 4.3. A comparação entre as Tabelas 4.2 e 4.3 permitem observar que os erros de comissão foram reduziram em torno de 51% em relação ao melhor limiar BAI. O Coeficiente Dice (DC) aumentou em torno de 58% em relação à média do melhor limiar BAI. Além disso, o valor da exatidão global aumentou (~95%) e ficou na ordem de 99% para todos os mapas refinados. No entanto, houve um aumento também dos erros de omissão em torno de 11% em relação à média do melhor limiar BAI. Desta forma, algumas pequenas manchas de áreas queimadas não foram detectadas. Além disso, o erro relativo, RelB, também apresentou uma redução significativa, em torno de 85% considerando a média do melhor limiar BAI.

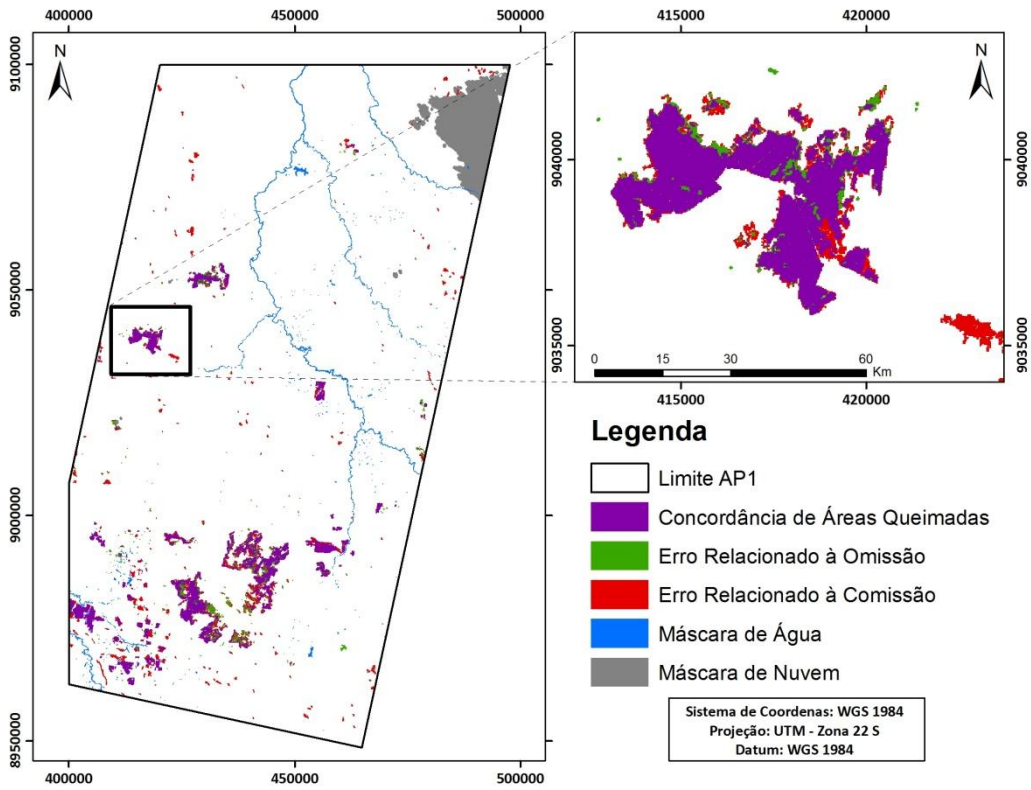
Vedovato et al. (2015), ao compararem o NBR e o MLME para uma região amazônica, reportaram que o NBR foi consistentemente capaz de distinguir áreas queimadas na maioria dos casos. No entanto, a confusão de áreas queimadas com solos expostos e corpos d'água foi observada devido à semelhança entre as respostas espectrais. Também foi observado que o tamanho das áreas queimadas aumenta o erro de detecção. Isto é, pequenas áreas de queimada podem não ser detectadas.

Tabela 4.3 - Eo, Ec, DC e RelB para os mapeamento refinado de áreas queimadas.

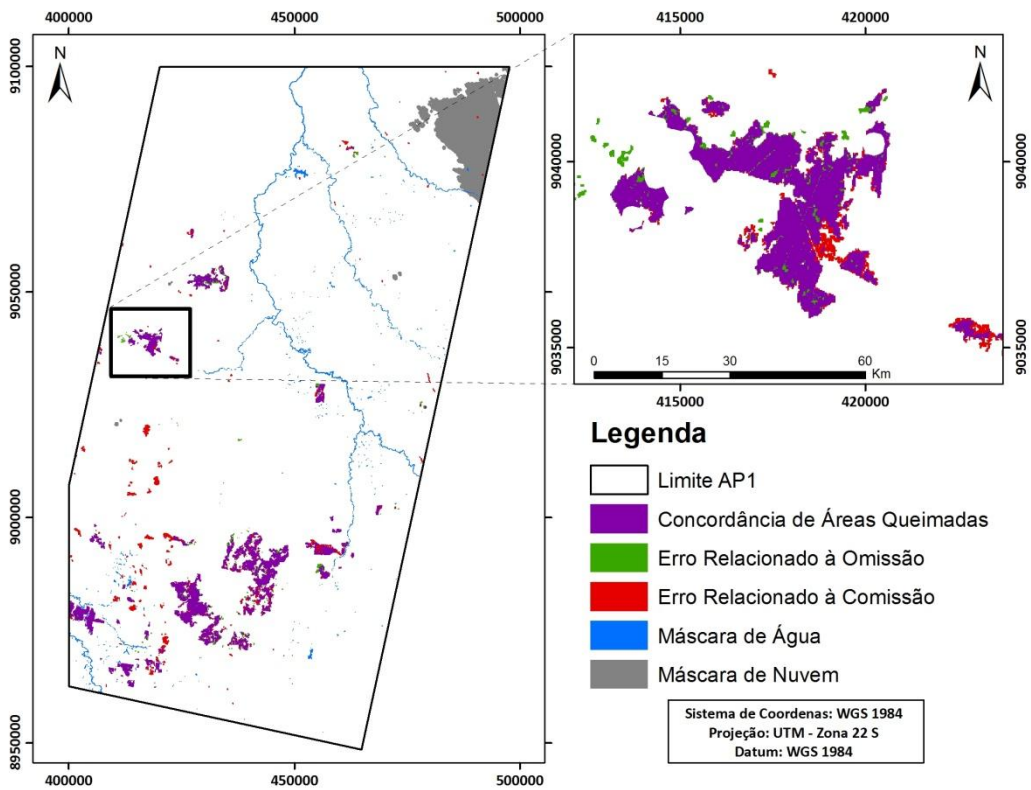
	AP1		AP2		Média
	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	Sentinel-2 MSI	
Eo	0,28	0,18	0,34	0,10	0,22
Ec	0,22	0,26	0,34	0,47	0,32
DC	0,75	0,78	0,66	0,67	0,71
RelB	38,82	49,82	30,66	65,90	46,3

Fonte: Produzido pelo autor.

Figura 4.7 - Mapa refinado de áreas queimadas após a etapa de filtragem para AP1: (A) imagem Landsat-8 OLI; (B) Imagem do Sentinel-2.



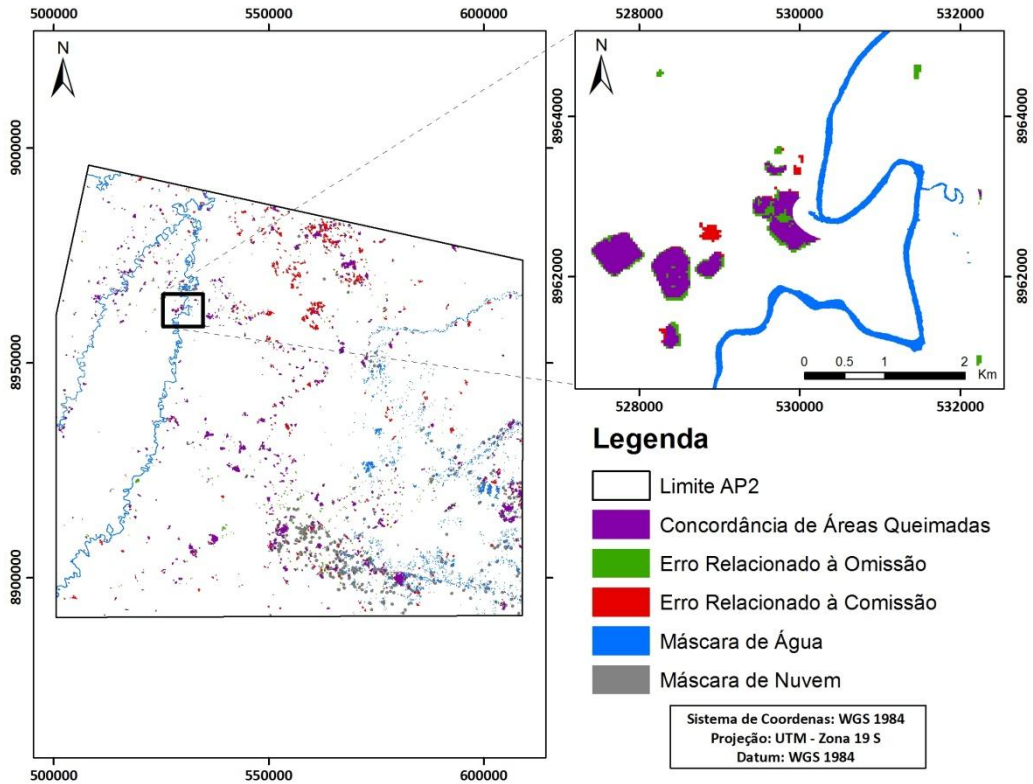
(A)



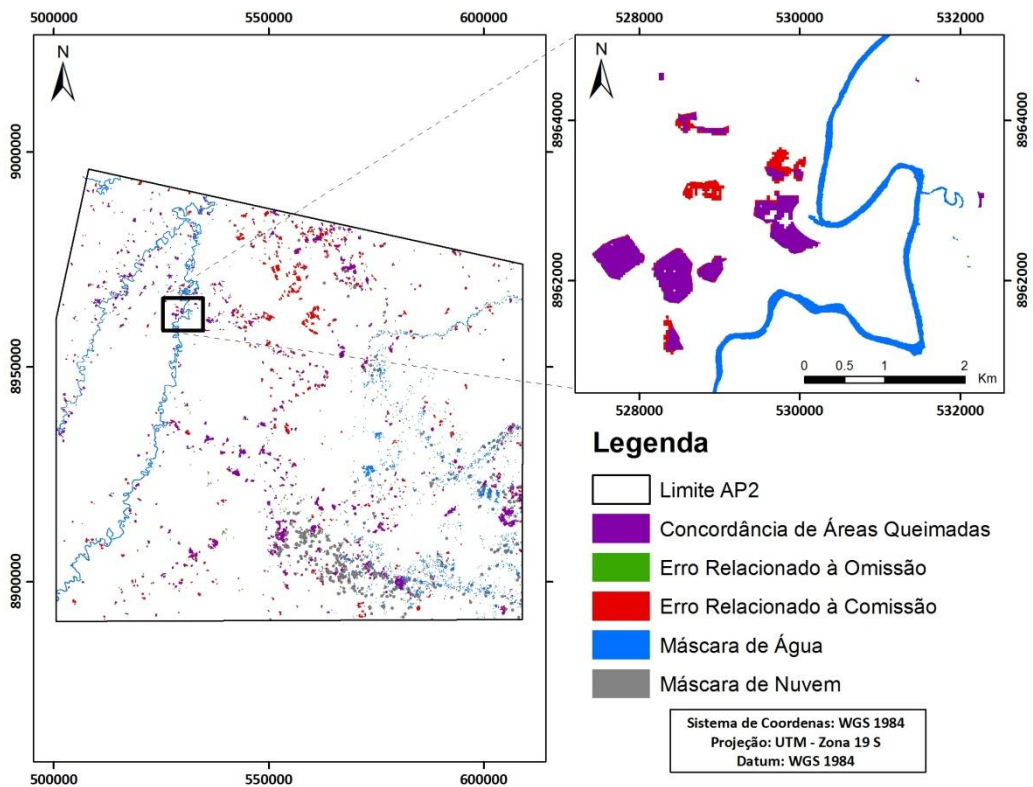
(B)

Fonte: Produzido pelo autor.

Figura 4.8 - Mapa refinado de áreas queimadas após a etapa de filtragem para AP2: (A) imagem Landsat-8 OLI; (B) Imagem do Sentinel-2.



(A)



(B)

Fonte: Produzido pelo autor.

Para apoiar a análise do mapeamento BAI refinado, a distribuição do tamanho das áreas queimadas detectadas foi avaliada. Os resultados são apresentados na Tabela 4.4. Além disso, o número de ocorrências de queimadas acumulado um mês antes da aquisição das imagens foi verificado, como mostra a Tabela 4.5.

Desta análise, observou-se que o tamanho da maioria dos polígonos de referência era inferior a 0,1 km². Para as duas áreas de estudo AP1 e AP2, a percentagem do número total de áreas queimadas mapeadas foi muito semelhante a dos polígonos de referência. As áreas de queimadas grandes (> 1 km²) foram cerca de 3% na AP1 e menos de 0,7% na AP2. Quanto aos tamanhos menores, a metodologia proposta foi muito eficaz. No entanto, a detecção de áreas queimadas superiores a 1 km² não foi eficiente. Isso pode ser explicado pela configuração dos parâmetros de segmentação adotada, que prioriza objetos pequenos.

Tabela 4.4 - Percentagem dos polígonos de áreas queimadas em cada AP e sensores em relação ao seu tamanho, definido em quatro intervalos.

Tamanho dos polígonos de áreas queimadas de referência (a) [km ²]	Percentagem do número total de áreas queimadas (Referência AP1) [%]		Percentagem do número total de áreas queimadas detectadas na AP1 [%]		Percentagem do número total de áreas queimadas (Referência AP2) [%]		Percentagem do número total de áreas queimadas detectadas na AP2 [%]	
	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	Sentinel-2 MSI
a < 0,1	85,40	82,10	84,45	82,27	86,95	87,93	89,35	89,77
0,1 < a < 0,3	7,25	8,90	7,63	9,15	9,62	8,89	9,44	8,98
0,3 < a < 0,9	4,30	5,35	4,60	5,05	2,72	2,51	1,11	1,25
a > 0,9	3,05	3,65	3,33	3,53	0,71	0,77	0,10	-

Fonte: Produzido pelo autor.

Em relação à concordância espacial dos produtos de fogo ativo NOAA VIIRS-NPP (375m) com os dados de referência e o mapa de áreas queimadas BAI refinado (Tabela 4.5), pode-se observar que a metodologia proposta apresentou elevada concordância com a metodologia baseada no MLME (verificar a Seção 3.1.2). Além disso, se considerada a área total mapeada pelo modelo refinado, observa-se na AP1 uma subestimação de áreas queimadas da ordem de 7% para a imagem Landsat-8 OLI e uma

superestimação de cerca de 10% para a imagem Sentinel-2 MSI. Para AP2, foi observada uma superestimação da área queimada em ambos os dados dos sensores da ordem de 2% para a imagem Landsat-8 OLI e cerca de 64% para a imagem Sentinel-2 MSI. Entretanto, foi observada uma redução substancial da superestimação das áreas queimadas em relação ao melhor limiar BAI (+/- 2,0 σ). Este resultado pode ser melhorado por meio de uma revisão da configuração do processo de segmentação ou alterando parâmetros do processo de filtragem.

Tabela 4.5 - Produto de fogo ativo NOAA VIIRS-NPP (375m) acumulado um mês antes da aquisição das imagens.

Áreas Pilotos	Produto de fogo ativo (Dado de referência)		Produto de fogo ativo (Mapa refinado)		
	[observado / total de ocorrência]		[observado / total de ocorrência]		
AP1	Landsat-8 OLI	907 / 1158	(78,32%)	909 / 1158	(78,50%)
	Sentinel-2 MSI	893 / 1158	(77,12%)	888 / 1158	(76,68%)
AP2	Landsat-8 OLI	556 / 620	(89,68%)	560 / 620	(90,32%)
	Sentinel-2 MSI	590 / 620	(95,16%)	586 / 620	(94,52%)

Fonte: Produzido pelo autor.

4.5. Resultados da Seleção de Atributos e Mineração de Dados

A Tabela 4.6 apresenta um resumo dos resultados obtidos no processo de seleção de atributos, considerando as tres áreas de estudo (AP1, AP2, AP3) e os tres sensores: OLI (Landsat-8), MUX (CBERS-4), MSI (Sentinel-2). Do conjunto inicial de atributos gerados, a dimensionalidade dos dados foi reduzida para cerca de 1% a 4% do total de atributos, usando as técnicas de mineração de dados. A Tabela 4.7 mostra os atributos selecionados pelo algoritmo CSF (verificar Seção 3.2.6) e a frequência de aparições destes atributos por AP.


Tabela 4.6 - Resumo do processo de seleção de atributos e mineração de dados.

Plataforma [Algoritmo]		AP1		AP2		AP3	
		OLI	MSI	OLI	MSI	OLI	MUX
eCognition [-]	Total de Atributos Gerados	290	294	448	548	282	266
Weka [CSF]	Número de atributos selecionados	11	6	17	5	9	9
Weka [J48]	Número de folhas	38	21	49	16	72	58
	Tamanho da árvore	75	41	97	31	143	115

Fonte: Produzido pelo autor.

Os atributos mais relevantes para a identificação de áreas queimadas foram os seguintes: 16 espectrais baseados em pixel, 9 espectrais baseados em objetos, 4 espaciais de textura e 1 atributo espacial de forma. Destes, destacam-se os atributos derivados das bandas do NIR e dos índices espectrais BAI e MIRBI (Figura 4.9), que melhor caracterizam as áreas queimadas.

Figura 4.9 - Frequência dos tipos de atributos por banda, selecionados pelo algoritmo CSF.



Fonte: Produzido pelo autor.

A Tabela 4.7 mostra os atributos selecionados para cada área de estudo e imagens. Pode-se observar que a seleção de atributos pelo algoritmo CSF é muito específica para cada área de estudo, embora tenha permitido identificar os atributos mais frequentes nos modelos de classificação e possibilitado a exclusão dos atributos redundantes.

Tabela 4.7 - Atributos selecionados pelo algoritmo CSF, para cada área de estudo.

Atributo	Tipo	AP1		AP2		AP3	
		OLI	MSI	OLI	MSI	OLI	MUX
<i>GLCM Homogeneity BAI</i>	Espacial Textura	✓	-	✓	✓	-	-
<i>GLCM Entropy BAI</i>	Espacial Textura	✓	-	✓	-	-	-
<i>Mean of outer border NIR</i>	Espectral Baseado em Pixel	✓	✓	✓	-	-	-
<i>GLCM Correlation MIRBI</i>	Espacial Textura	✓	✓	-	-	-	-
<i>Mean_of_inner_border_MIRBI</i>	Espectral Baseado em Pixel	✓	✓	-	-	-	-
<i>Mean of inner border BAI</i>	Espectral Baseado em Pixel	✓	✓	-	-	✓	-
<i>Mean of inner border NIR</i>	Espectral Baseado em Pixel	✓	-	✓	-	✓	-
<i>Main direction</i>	Espacial Forma	✓	-	-	-	-	✓
<i>Maximum of pixels MIRBI</i>	Espectral Baseado em Pixel	✓	-	✓	✓	-	-
<i>Quantile MIRBI</i>	Espectral Baseado em Objeto	✓	-	✓	-	-	-

(Continua).

Tabela 4.7 – Continuação.

Atributo	Tipo	AP1		AP2		AP3	
		OLI	MSI	OLI	MSI	OLI	MUX
<i>Quantile NIR</i>	Espectral Baseado em Objeto	✓	-	-	-	-	-
<i>Mode Minimum BAI</i>	Espectral Baseado em Objeto	-	✓	✓	-	✓	✓
<i>Mean Layer BAI</i>	Espectral Baseado em Objeto	-	✓	-	-	-	-
<i>Ratio Layer MIRBI</i>	Espectral Baseado em Pixel	-	-	✓	-	-	-
<i>Ratio Layer NDVI</i>	Espectral Baseado em Pixel	-	-	✓	-	-	-
<i>Contrast to neighbor pixels NIR</i>	Espectral Baseado em Pixel	-	-	✓	-	✓	✓
<i>GLCM Angular 2nd moment BAI</i>	Espacial Textura	-	-	✓	✓	-	-
<i>Mode Minimum NIR</i>	Espectral Baseado em Objeto	-	-	✓	-	-	-
<i>Circular StdDev/Mean BAI</i>	Espectral Baseado em Pixel	-	-	✓	-	✓	✓
<i>Maximum difference</i>	Espectral Baseado em Pixel	-	-	✓	-	-	-
<i>Mean Layer NIR</i>	Espectral Baseado em Objeto	-	-	✓	✓	-	✓
<i>Skewness BAI</i>	Espectral Baseado em Objeto	-	-	✓	-	✓	✓
<i>Circular StdDev/Mean MIRBI</i>	Espectral Baseado em Pixel	-	-	-	✓	-	-

(Continua).

Tabela 4.7 – Conclusão.

Atributo	Tipo	AP1		AP2		AP3	
		OLI	MSI	OLI	MSI	OLI	MUX
<i>Elliptic Fit</i>	Espectral Baseado em Pixel	-	-	-	-	✓	-
<i>Mean of outer border BAI</i>	Espectral Baseado em Pixel	-	-	-	-	✓	✓
<i>Skewness Blue</i>	Espectral Baseado em Objeto	-	-	-	-	✓	-
<i>Circular Mean NIR</i>	Espectral Baseado em Pixel	-	-	-	-	✓	-
<i>Ratio Layer Green</i>	Espectral Baseado em Pixel	-	-	-	-	-	✓
<i>Ratio Layer Blue</i>	Espectral Baseado em Pixel	-	-	-	-	-	✓

Fonte: Produzido pelo autor.

As árvores de decisão construídas pelo algoritmo J48 para cada AP e tipo de imagem são apresentadas no APÊNDICE C. Como opção de teste para geração dos modelos de classificação pelo algoritmo J48, o processo de validação cruzada (*Cross-validation*) com 10 repetições (*Folds*) foi utilizado. Observou-se que o tamanho das árvores de decisão variou bastante, gerando modelos muito específicos que impossibilitam indicar, de forma genérica, os atributos mais relevantes para a caracterização das áreas queimadas. Em contrapartida, a estrutura do classificador em forma de árvore permite entender como os atributos são combinados para diferenciar as áreas queimadas das áreas não queimadas.

As matrizes de confusão (APÊNDICE D) geradas pelo J48 permitiram extrair métricas com as taxas de acertos dos modelos (Tabela 4.8). De forma geral, observou-se que os erros de omissão (Eo) e comissão (Ec) foram baixos, média de 17% e 22%, respectivamente. Os valores de DC também foram considerados adequados (média de 0,80). Entretanto, os erros relativos (RelB) foram altos (média de 825,50). Isto significa que elementos da Superclasse *Não Queimadas* podem ter sido classificados como *Áreas*

Queimadas, por apresentarem características semelhantes na imagem. Isto fica claro na AP3 da imagem Landsat-8 OLI, na qual os resultados da classificação foram piores, o que pode ser explicado pelo alto percentual de áreas queimadas presentes (40% da área total da AP3) e pelo grande número de segmentos a serem classificados.

Tabela 4.8 - Eo, Ec, DC e RelB para os mapeamento de áreas queimadas refinados.

	AP1		AP2		AP3		Média
	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	Sentinel-2 MSI	Landsat-8 OLI	CBERS-4 MUX	
Eo	0,14	0,18	0,14	0,13	0,30	0,15	0,17
Ec	0,13	0,21	0,16	0,14	0,49	0,19	0,22
DC	0,87	0,80	0,85	0,86	0,59	0,83	0,80
RelB	300,86	418,82	492,86	397,87	2454,70	887,85	825,50

Fonte: Produzido pelo autor.

4.6. Modelos de Detecção de Áreas Queimadas por Árvore de Decisão

A Tabela 4.9 apresenta o resultado do modelo majoritário de detecção de áreas queimadas. A partir das árvores de decisão geradas pelo algoritmo J48, foi possível extrair o caminho majoritário, ou seja, o caminho principal desde a “raiz” da árvore até a folha que contém o maior número de instâncias corretamente classificadas. A redução ou recorte dos modelos de classificação por meio do caminho majoritário propicia à generalização dos modelos de detecção de áreas queimadas, assim como a identificação dos atributos mais relevantes para detecção das *Áreas Queimadas*.

Tabela 4.9 - Modelos de classificação pelo caminho majoritário [n° de amostras/n° total de amostras].

AP1	
OLI	MSI
<i>Quantile NIR</i> <= 2007.5	<i>Mean of inner border MIRBI</i> > 0.7494
<i>Maximum of pixels MIRBI</i> > 0.9091	<i>Mean of outer border NIR</i> <= 2311.56044
<i>GLCM Entropy BAI</i> <= 4.9769	<i>Mean of outer border BAI</i> <= 0.1560
<i>Mean of outer border NIR</i> <= 2434.3272	<i>GLCM Correlation MIRBI</i> <= 0.6754
<i>Main direction</i> > 1.0102	<i>Mean of outer border NIR</i> > 1082.06
<i>Quantile MIRBI</i> > 0.8960	<i>Mode Minimum BAI</i> > 0.9994
<i>Mean of inner border NIR</i> <= 1882.1086:	<i>Mean of inner border MIRBI</i> >
Áreas Queimadas [1086/2320]	0.8105: Áreas Queimadas [976/2010]
AP2	
OLI	MSI
<i>Mean of inner border NIR</i> <= 2483	<i>Mean Layer NIR</i> <= 2536.8297
<i>GLCM Homogeneity BAI</i> > 0.2311	<i>GLCM Homogeneity BAI</i> > 0.2311
<i>Mean of outer border NIR</i> <= 2648.5	<i>GLCM Homogeneity BAI</i> > 0.3929
<i>GLCM Homogeneity BAI</i> <= 0.6763	<i>GLCM Homogeneity BAI</i> <= 0.5157:
<i>Skewness BAI</i> <= 0.0133	Áreas Queimadas [328/2762]
<i>Skewness BAI</i> > 0.0133: Áreas Queimadas	<i>GLCM Homogeneity BAI</i> > 0.5157
[862/3056]	<i>GLCM Homogeneity BAI</i> <= 0.9729:
<i>GLCM Homogeneity BAI</i> > 0.6763: Áreas	Áreas Queimadas [671/2762]
Queimadas [407.0/3056]	

(Continua).

Tabela 4.9 – Continuação.

AP3	
OLI	MUX
<i>Circular Mean NIR</i> <= 2456.125	<i>Mean Layer NIR</i> <= 45.4878
<i>Skewness BAI</i> > 0.7854	<i>Contrast neighbor pixels NIR</i> <= 11.5482
<i>Mean of outer border BAI</i> <= 0.3922	<i>Mean of outer border BAI</i> <= 0.5208
<i>Skewness Blue</i> <= -0.5905: Áreas Queimadas [1229/5028]	<i>Skewness BAI</i> > 0.8340
	<i>Ratio Layer Blue</i> > 0.2950: Áreas Queimadas [1969/4570]

Fonte: Produzido pelo autor.

A Tabela 4.10 resume a quantidade de objetos classificados corretamente como *Áreas Queimadas* pelo caminho majoritário de cada AP e tipo de imagem. Observou-se que, em média, 42% dos elementos da classe *Áreas Queimadas* são identificadas pelo caminho majoritário, o que representa uma média de 21 ramos e 7 nós de decisão para AP1, 15 ramos e 6,5 nós de decisão na AP2 e 8 ramos e 4,5 nós de decisão para AP3. Em relação ao modelo de classificação completo gerado pelo J48, ocorreu uma redução média do tamanho da árvore de 86% para AP1, 87% para AP2 e 97% para AP3. Em outras palavras, os modelos por caminho majoritário com tamanho médio de 10% das árvores de decisão originais detectam, em média, 42% das *Áreas Queimadas*. Nesse sentido, a priorização dos atributos majoritários identificados pelas árvores de decisão, utilizando este novo subconjunto de atributos em uma nova rodada de classificação, pode refinar o modelo de detecção de áreas queimadas.

A dificuldade de generalização e replicação de modelos de classificação para outras áreas já foi estudada por Neves (2017) para áreas de pastagens na Amazônia utilizando técnicas de mineração de dados e GEOBIA, além de amostras mistas e diferentes algoritmos de classificação. Esta autora não observou vantagens em replicar os modelos gerados para outras áreas - sugerindo a criação de modelos independentes. Os experimentos realizados indicam que se deve abranger ao máximo os diferentes padrões da classe alvo no momento da coleta de amostras, assim como, considerar os diversos fatores e especificidades que influenciam as áreas de estudo, tais como, os parâmetros

ambientais (vegetação, clima e bioma), tipos de coberturas e tipos de manejo da terra – corroborando assim para as observações de Libonati et al. (2015).

Tabela 4.10 - Resumo dos modelos de classificação pelo caminho majoritário.

	AP1		AP2		AP3	
	OLI	MSI	OLI	MSI	OLI	MUX
Quantidade de instâncias identificadas como Áreas Queimadas [%]	47%	49%	42%	36%	34%	46%
Número de ramos	21	21	17	13	6	10
Tamanho da árvore	7	7	7	6	4	5

Fonte: Produzido pelo autor.

4.7. Atributos Descritores de Áreas Queimadas

A Tabela 4.11 mostra os melhores atributos descritores das áreas queimadas segundo os modelos de detecção pelo caminho majoritário para cada AP e tipo de imagem. Os principais atributos descritores são: 8 espectrais baseados em pixel, 7 espectrais baseados em objetos, 4 espaciais de textura e 1 espacial de forma.

Destes atributos, 10 derivam da banda NIR, 10 do índice BAI e 4 do índice MIRBI. Este resultado corrobora com os estudos de Pereira e Setzer (1993), que caracterizaram o comportamento espectral das áreas queimadas em uma região da Amazônia por uma diminuição da reflectância nas bandas visíveis e NIR, e um aumento nas bandas de ondas curtas do infravermelho médio, utilizando imagens Landsat-5 TM. Além dos estudos de Pereira (1999); Libonati et al., (2012) e Pereira et al. (2016) que indicam a utilização de índices espectrais e de bandas espectrais cujos intervalos do espectro eletromagnético contemplem as faixas NIR e SWIR para a detecção de áreas queimadas.

O gráfico da Figura 4.10 apresenta o número de ocorrência dos atributos nos modelos. Para as três áreas de estudo AP1, AP2 e AP3, os atributos mais relevantes para a

caracterização de áreas queimadas são provenientes da banda NIR: *Mean of outer border* (Espectral baseado em pixel), com 3 aparições, *Mean of inner border* (Espectral baseado em pixel) e *Mean Layer* (Espectral baseado em objeto), com 2 aparições cada nos modelos. Além dos atributos do índice BAI: *GLCM_Homogeneity* (Espacial de Textura), *Mean of outer border* (Espectral baseado em pixel) e *Mean of inner border* (Espectral baseado em pixel), com 2 aparições cada nos modelos, além do *Skewness* (Espectral baseado em objeto), com 3 aparições. Na Tabela 4.11 são apresentados os melhores atributos descritores das áreas queimadas segundo os modelos detecção pelo caminho majoritário para cada AP e tipo de imagem. Observou-se que os principais atributos descritores foram: 8 espectrais baseados em pixel, 7 espectrais baseados em objetos, 4 espaciais de textura e 1 espacial de forma.

Tabela 4.11 - Principais atributos identificados para o modelo de detecção de áreas queimadas pelo caminho majoritário.

Área de Estudo	Atributo	Tipo	Ocorrências no modelo	
API	OLI	<i>Quantile NIR</i>	Espectral Baseado em Objeto	1
		<i>Maximum of pixels MIRBI</i>	Espectral Baseado em Pixel	1
		<i>GLCM Entropy BAI</i>	Espacial Textura	1
		<i>Mean of outer border NIR</i>	Espectral Baseado em Pixel	1
		<i>Main direction</i>	Espacial Forma	1
		<i>Quantile MIRBI</i>	Espectral Baseado em Objeto	1
		<i>Mean of inner border NIR</i>	Espectral Baseado em Pixel	1
	MSI	<i>Mean of inner border MIRBI</i>	Espectral Baseado em Pixel	2
		<i>Mean of outer border NIR</i>	Espectral Baseado em Pixel	2
		<i>Mean of inner border BAI</i>	Espectral Baseado em Pixel	1
		<i>GLCM Correlation MIRBI</i>	Espacial Textura	1
		<i>Mode Minimum BAI</i>	Espectral Baseado em Objeto	1


(Continua).

Tabela 4.11 – Continuação.

AP2	OLI	<i>Mean of inner border NIR</i>	Espectral Baseado em Pixel	1
		<i>GLCM Homogeneity BAI</i>	Espacial Textura	2
		<i>Mean of outer border NIR</i>	Espectral Baseado em Pixel	1
		<i>Skewness BAI</i>	Espectral Baseado em Objeto	2
	MSI	<i>Mean Layer NIR</i>	Espectral Baseado em Objeto	1
		<i>GLCM Homogeneity BAI</i>	Espacial Textura	5
AP3	OLI	<i>Circular Mean NIR</i>	Espectral Baseado em Pixel	1
		<i>Skewness BAI</i>	Espectral Baseado em Objeto	1
		<i>Mean of outer border BAI</i>	Espectral Baseado em Pixel	1
		<i>Skewness Blue</i>	Espectral Baseado em Objeto	1
	MUX	<i>Mean Layer NIR</i>	Espectral Baseado em Objeto	1
<i>Contrast neighbor pixels NIR</i>		Espectral Baseado em Pixel	1	
<i>Mean of outer border BAI</i>		Espectral Baseado em Pixel	1	
<i>Skewness BAI</i>		Espectral Baseado em Objeto	1	
<i>Ratio Layer Blue</i>		Espectral Baseado em Pixel	1	

Fonte: Produzido pelo autor.

Figura 4.10 - Número de ocorrência dos principais atributos descritores segundo os modelos de detecção de áreas queimadas pelo caminho majoritário.



Fonte: Produzido pelo autor.

4.8. Imagens de Média Resolução Espacial para Detecção de Áreas Queimadas

Neste estudo, a metodologia foi desenvolvida sob uma perspectiva de imagens de média resolução espacial, tendo em vista a necessidade do desenvolvimento de mapeamentos mais refinados de áreas queimadas para a Amazônia, conforme verificado na literatura (LIMA, 2013; SHIMABUKURO et al., 2015; ANDERSON et al., 2015). Além do aumento da disponibilidade de dados desta natureza que podem suportar estudos mais detalhados de detecção e monitoramento de queimadas com maior resolução temporal ou preenchendo lacunas de séries temporais (BOSCHETTI et al., 2015; BENDINI et al., 2016; HUANG et al., 2016).

Nesse sentido, a primeira fase deste estudo usou duas imagens Landsat-8 OLI e duas imagens Sentinel-2 MSI para duas áreas de estudo AP1 e AP2. Na segunda fase, a área de estudo AP3 foi incluída e imagens do Landsat-8 OLI e CBERS-4 MUX foram usadas. Todas as etapas de pré-processamento foram realizadas para compatibilizar as imagens, definindo a resolução espacial de 30m como referência.

Os resultados obtidos indicam que há diferenças na detecção de áreas queimadas dependendo do tipo de imagem. Parte disso pode ser explicada pelas características inerentes dos sensores OLI, MSI e MUX. Por mais que sejam espectralmente e espacialmente compatíveis, os sensores apresentam diferenças radiométricas, forma de aquisição, bem como nas técnicas usadas para correção geométrica e atmosférica (FONSECA; MANJUNATH, 1996; MOUSIVAND et al., 2015; MANDANCINI; BITELLI, 2016). Consequentemente, estas variações nas imagens podem acarretar diferenças nos modelos de classificação e seleção dos atributos descritores das áreas queimadas.

Alguns aspectos relativos aos resultados merecem destaque. Os índices espectrais apresentaram potencial de uso em imagens de média resolução espacial, dentre os quais, o BAI se apresentou como o índice mais indicado para a detecção de áreas queimadas nas três áreas de estudo. Além disso, os atributos derivados do BAI e da banda NIR se destacaram nos modelos de classificação por área de decisão; eles podem ser replicados para imagens dos três sensores testados, assim como, para outras áreas de estudos na Amazônia.

5 CONCLUSÕES

No presente trabalho, diversos métodos de SR foram experimentados em diferentes APs visando desenvolver uma metodologia para detecção de áreas queimadas na Amazônia, utilizando imagens de média resolução espacial. Com base na exploração de índices espectrais e por meio da extração de atributos descritores - combinando técnicas de GEOBIA e mineração de dados - a detecção e o mapeamento de áreas queimadas foram refinados.

Na primeira fase foram apresentados os métodos de compatibilização de imagens de média resolução espacial, a aplicação de diferentes índices espectrais baseada na literatura, a realização de testes estatísticos para determinar os melhores índices espectrais para detecção de áreas queimadas bem como os limiares mais adequados. Verificou-se que para o refinamento da detecção de áreas queimadas, a utilização de GEOBIA como uma etapa de filtragem se fez pertinente.

Ao comparar os índices espectrais, constatou-se que o BAI apresentou resultados estatísticos robustos para a discriminação de áreas queimadas (1º no ranking dos índices de acordo com a estatística M) nas AP1 e AP2 bem como em ambas as imagens Landsat-8 OLI e Sentinel-2 MSI. Os índices MIRBI e NBR2 também apresentaram resultados satisfatórios para alguns casos.

Nos testes de limiares, observou-se que por mais que o limiar de $\pm 2,0 \sigma$ fosse capaz de incluir a maioria das áreas queimadas e não omitir uma quantidade relevante de informações, com baixos erros médios de omissão ($E_o \sim 0,18$). Além disso, várias manchas pequenas foram detectadas (falsos positivos) o que representa elevados erros médios de comissão ($E_c \sim 0,63$) acarretando em superestimação da área total mapeada (da ordem de $\sim 160\%$ na AP1 e 540% na AP2). Concluiu-se, portanto, que devido à inclusão incorreta de alvos com semelhança espectral (*e.g.* nuvens, sombras e corpos hídricos), a utilização de um limiar fixo em índices para detecção de áreas queimadas não é recomendada.

Ao construir um modelo de detecção de áreas queimadas baseado em GEOBIA como etapa de filtragem, verificou-se o potencial desta técnica para o refinamento dos resultados. A construção de um modelo com base no conhecimento do especialista, a

utilização de um algoritmo de segmentação para um delineamento mais adequado das áreas queimadas, assim como, a aplicação de máscaras (para os alvos água e nuvem) e índices, contribuiu para diminuir os erros de comissão (redução de cerca de 51%) e melhorar a exatidão do mapeamento (aumento do DC de 58% e diminuição do RelB na ordem de 85%). Conclui-se, portanto, que o modelo baseado em GEOBIA possibilitou a detecção de pequenas manchas de áreas queimadas ($< 0,1 \text{ km}^2$), sendo eficiente também ao identificar um número total de áreas queimadas semelhantes à referência, diminuindo as superestimativas do total de áreas mapeadas e os erros de omissão e comissão.

O uso do algoritmo CFS para a seleção de atributos revelou-se útil ao reduzir a dimensionalidade do conjunto inicial de atributos (redução para cerca de 1% a 4% do total de atributos). A escolha do método por árvore de decisão (J48) se mostrou adequado, uma vez que permitiu entender como os atributos são combinados para diferenciar as *Áreas Queimadas* das *Áreas Não Queimadas*. Os resultados das árvores de decisão foram considerados confiáveis (DC com média de 0,80; erros de omissão (Eo) e comissão (Ec) médios de 17% e 22%, respectivamente) dando suporte às análises subsequentes.

Além disso, analisou-se que por meio do caminho majoritário, os modelos de detecção por árvores de decisão apresentaram tamanho médio de 10% das árvores de decisão originais e foram capazes de detectar em média 42% das áreas queimadas – sendo estes atributos os mais relevantes para a construção de novos modelos. Os melhores atributos identificados são provenientes da banda NIR: *Mean of outer border* (Espectral baseado em pixel), *Mean of inner border* (Espectral baseado em pixel) e *Mean Layer* (Espectral baseado em objeto). Além dos atributos do índice BAI: *GLCM_Homogeneity* (Espacial de Textura), *Mean of outer border* (Espectral baseado em pixel) e *Mean of inner border* (Espectral baseado em pixel), *Skewness* (Espectral baseado em objeto). Portanto, indica-se, utilizar estes atributos como novo subconjunto para a construção de novos modelos de detecção de áreas queimadas. Ademais, os resultados indicam que a utilização de índices espectrais e de bandas espectrais cujos intervalos do espectro eletromagnético contemplem as faixas do NIR e SWIR são os mais indicados para a detecção de áreas queimadas.

A potencialidade das imagens de média resolução espacial no mapeamento de áreas queimadas na Amazônia foi verificada. Os resultados indicam que as diferenças

observadas nos tipos de imagens podem ser explicadas pelas características inerentes dos sensores OLI, MSI e MUX. Embora isto não inviabilize o uso combinado destes sensores, sendo considerados compatíveis por Mandanici e Bitelli (2016); Pinto et al., (2016); Bendini et al. (2016). Em contrapartida, os melhores resultados, tais como a aplicação do índice BAI e a extração dos atributos descritores, são possíveis de ser replicados nos sensores estudados. Desta forma, representando um avanço ao permitir a obtenção de imagens em diferentes datas e localidades para o monitoramento/mapeamento de áreas queimadas na Amazônia.

Por fim, a utilização de imagens de média resolução contribui para refinar a detecção de áreas queimadas, no entanto, implica na geração de um volume maior de dados e demanda a utilização de técnicas complexas de SR para a extração de informações, o que do ponto de vista operacional requer novos experimentos para o desenvolvimento de uma metodologia mais simples e robusta.

Algumas recomendações e sugestões para trabalhos futuros são apresentados:

- a) Testar a metodologia proposta para outras áreas de estudo na Amazônia e em outros tipos de imagens de média resolução espacial;
- b) Considerando uma abordagem bi-temporal (pré e pós-queimada), verificar se o BAI é o índice espectral mais adequado para a detecção de áreas queimadas;
- c) Estudar a influência da aplicação de índices espectrais e identificação de atributos descritores das áreas queimadas em diferentes tipos de cobertura da terra
- d) Investigar outros algoritmos de classificação (*e.g. Random Forest e Support Vector Machine*) para a detecção de áreas queimadas utilizando a mesma metodologia;

REFERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, A.; NEPSTAD, D.; DEL CARMEN VERA DIAZ, M. Forest understory fire in the Brazilian Amazon in ENSO and non-ENSO years: area burned and committed carbon emissions. **Earth Interactions**, v. 10, n. 6, 2006.

ALMEIDA, C. A.; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.

ALMEIDA-FILHO, R.; SHIMABUKURO, Y. E. Digital processing of a Landsat-TM time series for mapping and monitoring degraded areas caused by independent gold miners, Roraima state, Brazilian Amazon. **Remote Sensing of Environment**, v. 79, n. 1, p. 42–50, 2002.

ANDERSON, L. O.; ARAGÃO, L. E. O. C.; GLOOR, M.; ARAI, E.; ADAMI, M.; SAATCHI, S. S.; MALHI, Y.; SHIMABUKURO, Y. E.; BARLOW, J.; BERENGUER, E.; DUARTE, V. Disentangling the contribution of multiple land covers to fire-mediated carbon emissions in Amazonia during the 2010 drought. **Global Biogeochemical Cycles**, v. 29, n. 10, p. 1739–1753, 2015.

ANDERSON, L. O.; ARAGÃO, L. E. O. E. 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.; CHEEK, D.; ARAGAO, L. E.; ANDERE, L.; DUARTE, B.; SALAZAR, N.; LIMA, A.; DUARTE, V.; ARAI, E. Development of a point-based method for map validation and confidence interval estimation: a case study of burned areas in Amazonia. **Journal of Remote Sensing & GIS**, v. 6, n. 1, p. 1–9, 2017.

ARAGÃO, L. E. O. C.; ANDERSON, L. O.; FONSECA, M. G.; ROSAN, T. M.; VEDOVATO, L.; WAGNER, F.; SILVA JUNIOR, C. H. L.; ARAI, E.; AGUIAR, A. P.; NARLOW, J.; BERENGUER, E.; DEETER, M.; DOMINGUES, L.; GATTI, L.; GLOOR, M.; MALHI, Y.; MARENGO, J.; MILLER, J.; PHILLIPS, O.; SAATCHI, S. 21st century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, p. 1–12, 2018.

ARAGÃO, L. E. O. C.; ANDERSON, L. O.; LIMA, A.; ARAI, E. Fires in Amazonia. In: NAGY, L.; ARTAXO, P.; FORSBERG, B. R. (Eds). **Interactions between biosphere, atmosphere, and human land use in the Amazon basin: an introduction**. Berlin Heidelberg: Springer-Verlag, 2016. p.301-229.

ARAGÃO, L. E. O. C.; MALHI, Y.; BARBIER, N.; LIMA, A. A.; SHIMABUKURO, Y.; ANDERSON, L.; SAATCHI, S. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions of the Royal Society of London, Series B: Biological Sciences**, v. 363, n. 1498, p. 1779–85, 2008.

ARAGÃO, L. E. O. C.; MALHI, Y.; ROMAN-CUESTA, R. M.; SAATCHI, S.; ANDERSON, L. O.; SHIMABUKURO, Y. E. Spatial patterns and fire response of recent Amazonian droughts. **Geophysical Research Letters**, v. 34, n. 7, p. 1–5, 2007.

- ARAGÃO, L. E. O. C.; POULTER, B.; BARLOW, J. B.; ANDERSON, L. O.; MALHI, Y.; SAATCHI, S.; PHILLIPS, O. L.; GLOOR, E. Environmental change and the carbon balance of amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913–931, 2014.
- ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E. The incidence of fire in Amazonian forests with implications for REDD. **Science**, v. 328, n. 5983, p. 1275–1278, 2010.
- ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E.; CARDOSO, M.; ANDERSON, L. O.; LIMA, A.; POULTER, B. Frequência de queimadas durante secas recentes. In: BORMA, L. S.; NOBRE, C. A. (Eds). **Secas na Amazônia: causas e consequências**. São Paulo: Oficina de textos, 2013. p. 259–279.
- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation : an optimization approach for high quality multi-scale image segmentation. **Journal of Photogrammetry and Remote Sensing**, v. 58, n. 3–4, p. 12–23, 2000.
- BARLOW, J.; PERES, C. A. Fire-mediated dieback and compositional cascade in an amazonian forest. **Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences**, v. 363, n. 1498, p. 1787–1794, 2008.
- BARLOW, J.; PERES, C. A.; LAGAN, B. O.; HAUGAASEN, T. Large tree mortality and the decline of forest biomass following amazonian wildfires. **Ecology Letters**, v. 6, n. 1, p. 6–8, 2003.
- BASTARRIKA, A.; ALVARADO, M.; ARTANO, K.; MARTINEZ, M. P.; MESANZA, A.; TORRE, L.; RAMO, R.; CHUVIECO, E. BAMS: a tool for supervised burned area mapping using Landsat data. **Remote Sensing**, v. 6, n. 12, p. 12360–12380, 2014.
- BASTARRIKA, A.; CHUVIECO, E.; MARTÍN, M. P. Mapping burned areas from Landsat TM/ETM+ data with a two-phase algorithm: balancing omission and commission errors. **Remote Sensing of Environment**, v. 115, n. 4, p. 1003–1012, 2011.
- BENDINI, H. N.; FONSECA, L. M. G.; KÖRTING, T. S.; RENNAN, F. B. Assessment of a multi-sensor approach for noise removal on OLI/Landsat-8 time series using MUX/CBERS-4 data to improve a crop classification method based on phenological features. In: BRAZILIAN SYMPOSIUM ON GEOINFORMATICS, 17, 2016, Campos do Jordão-SP. **Proceedings...** GeoInfo Series, 2016, p. 12. Disponível em: < http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtc-m21b/2016/12.19.12.53/doc/bendini_assessment.pdf?requiredmirror=sid.inpe.br/mtc-m21b/2013/09.26.14.25.22&searchmirror=sid.inpe.br/bibdigital@80/2006/04.07.15.50.13&metadataarepository=sid.inpe.br/mtc-m21b/2016/12.19.12.53.04&choice=briefTitleAuthorMisc&searchsite=bibdigital.sid.inpe.br:80&languagebutton=en>. Acesso em: 1 out. 2017.
- BIRTH, G. S.; MCVEY, G. R. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, n. 6, p.640-643, 1968.

- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 2-16, 2010.
- BLASCHKE, T.; HAY, J. G.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; MEER, F. Van der; WERFF, H. Van der; COILLIE, F. Van; TIEDE, D. Geographic Object-based Image Analysis – towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180-191, 2014.
- BLASCHKE, T.; KUX, H. J. H. **Sensoriamento remoto e SIG avançados: novos sistemas sensores: métodos inovadores**. 2.ed. São Paulo: Oficina de Textos, 2007. 303 p.
- BOSCHETTI, L.; ROY, D. P.; JUSTICE, C. O.; HUMBER, M. L. MODIS-Landsat fusion for large area 30m burned area mapping. **Remote Sensing of Environment**, v. 161, p. 27–42, 2015.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BUSH, M. B.; SILMAN, M. R.; DE TOLEDO, M. B.; LISTOPAD, C.; GOSLING, W. D.; WILLIAMS, C.; DE OLIVEIRA, P. E.; KRISEL, C. Holocene fire and occupation in Amazonia: records from two lake districts. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 362, n. 1478, p. 209–218, 2007.
- CHUVIECO, E.; CONGALTON, R. G. Mapping and inventory of forest fires from digital processing of TM data mapping and inventory of forest fires from digital processing of TM data. **Geocarto International**, v. 3, n. 4, p. 41–53, 1988.
- CHUVIECO, E.; MART, M. P.; PALACIOS, A. Assessment of different spectral indices in the red–near-infrared spectral domain for burned land discrimination. **International Journal of Remote Sensing**, v. 23, n. 23, p. 5103–5110, 2002.
- COCHRANE, M. A. Fire science for rainforests. **Nature**, v. 421, n. 6926, p. 913–919, 2003.
- COCHRANE, M. A.; ALENCAR, A.; SCHULZE, M. D.; SOUZA, C. M.; NEPSTAD, D. C.; LEFEBVRE, P.; DAVIDSON, E. Positive feedbacks in the fire dynamic of closed canopy tropical forests. **Science**, New York, v. 284, n. 5421, p. 1832–5, 1999.
- COCHRANE, M. A.; SOUZA, C. M. Linear mixture model classification of burned forests in the eastern Amazon. **International Journal of Remote Sensing**, v. 19, n. 17, p. 3433–3440, 1998.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: CRC Press, 2009. V.2, p.183.
- CONGALTON, R.; GREEN, K. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire Scientific**, v. 10, p. 321–328, 2001.
- DA SILVA CARDOZO, F.; PEREIRA, G.; SHIMABUKURO, Y. E.; MORAES, E. C. Analysis and assessment of the spatial and temporal distribution of burned areas in the amazon forest. **Remote Sensing**, v. 6, n. 9, p. 8002–8025, 2014.
- DEPUY, V.; BERGER, V. W. .; ZHOU, Y. Wilcoxon – mann-whitney. In: EVERITT, B. S.; HOWELL, D. C. (Orgs.). **Encyclopedia of statistics in behavioral science**. Chinchester: John Wiley & Sons,, 2005. v. 4, P.2118–2121.

- DICE, L. R. Measures of the amount of ecologic association between species. **Ecology**, v.26, p.297–302, 1945.
- DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.
- EHLERS, M.; JANOWSKY, R.; GAEHLER, M. New remote sensing concepts for environmental monitoring. **Remote Sensing for Environmental Monitoring**, v. 4545, p. 1–12, 2002.
- FANIN, T.; VAN DER WERF, G. R. Relationships between burned area, forest cover loss, and land cover change in the brazilian amazon based on satellite data. **Biogeosciences**, v. 12, n. 20, p. 6033–6043, 2015.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37, 1996.
- FEARNSIDE, P. M. Deforestation in brazilian Amazonia: history, rates, and consequences. **Conservation Biology**, v. 19, n. 3, p. 680–688, 2005.
- FISCH, G.; MARENGO, J. A.; NOBRE, C. A. Uma revisão geral sobre o clima da Amazônia. **Acta Amazonica**, v.28, n.2, p.101-126, 1998.
- FONSECA, L. M. G.; MANJUNATH, B. S. Registration techniques for multisensor remotely sensed imagery. **Photogrammetric Engineering & Remote Sensing**, v. 62, p. 1049–1056, Sept. 1996.
- FRANÇA, D. G. M. **Comparação entre classificações de cobertura do solo urbano derivadas do WV-2 quanto ao nível da legenda de classificação**: estudo de caso para um setor da UNICAMP, SP. 2017. 217p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.
- FRANÇA, H.; SETZER, A. W. AVHRR analysis of a savanna site through a fire season in Brazil. **International Journal of Remote Sensing**, v. 22, n. 13, p. 2449–2461, 2001.
- GARCÍA, M.; CHUVIECO, E. Assessment of the potential of SAC-C/MMRS imagery for mapping burned areas in Spain. **Remote Sensing of Environment**, v. 92, n. 3, p. 414–423, 2004.
- GIGLIO, L.; SCHROEDER, W.; JUSTICE, C. O. The collection 6 MODIS active fire detection algorithm and fire products. **Remote Sensing of Environment**, v. 178, p. 31–41, 2016.
- GITAS, I. Z.; MITRI, G. H.; VENTURA, G. Object-based image classification for burned area mapping of Creus Cape, Spain, using NOAA-AVHRR imagery. **Remote Sensing of Environment**, v. 92, n. 3, p. 409–413, 2004.
- GUERRA, J.B.; MURA, J. C.; FREITAS, C. C. Discriminação de incrementos de desflorestamento na Amazônia com dados SAR R99B em banda L. **Acta Amazonica**, v.40, n.3, p.557-566, 2010.
- HALL M.; FRANK, E., HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA Data Mining Software: an update. **SIGKDD Explorations**, v. 11, n. 1, 2009.

HALL, M. A. **Correlation-based feature selection for machine learning**. 1999. 178p. Tese (Doutorado em Ciência da Computação) - Universidade de Waikato, Hamilton, Nova Zelândia, 1999.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: concepts and techniques**. 3.ed. San Mateo, CA: Morgan Kaufmann, 2012.

HANTSON, S.; ARNETH, A.; HARRISON, S. P.; KELLEY, D. I.; COLIN PRENTICE, I.; RABIN, S. S.; ARCHIBALD, S.; MOUILLOT, F.; ARNOLD, S. R.; ARTAXO, P.; BACHELET, D.; CIAIS, P.; FORREST, M.; FRIEDLINGSTEIN, P.; HICKLER, T.; KAPLAN, J. O.; KLOSTER, S.; KNORR, W.; LASSLOP, G.; LI, F.; MANGEON, S.; MELTON, J. R.; MEYN, A.; SITCH, S.; SPESSA, A.; VAN DER WERF, G. R.; VOULGARAKIS, A.; YUE, C. The status and challenge of global fire modelling. **Biogeosciences**, v. 13, n. 11, p. 3359–3375, 2016.

HARALICK, R.; SHANMUGAN, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 6, p.610-621, 1973.

HAWBAKER, T. J.; VANDERHOOF, M. K.; BEAL, Y. J.; TAKACS, J. D.; SCHMIDT, G. L.; FALGOUT, J. T.; WILLIAMS, B.; FAIRAUX, N. M.; CALDWELL, M. K.; PICOTTE, J. J.; HOWARD, S. M.; STITT, S.; DWYER, J. L. Mapping burned areas using dense time-series of Landsat data. **Remote Sensing of Environment**, v. 198, p. 504–522, 2017.

HAY, G. J.; CASTILLA, G. Geographic object-based image analysis (GEOBIA): a new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Eds.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer-Verlag, 2008. p.75-90.

HOLDEN, Z. A.; SMITH, A. M. S.; MORGAN, P.; ROLLINS, M. G.; GESSLER, P. E. Evaluation of novel thermally enhanced spectral indices for mapping fire perimeters and comparisons with fire atlas data. **International Journal of Remote Sensing**, v. 26, n. 21, p. 4801–4808, 2005.

HUANG, H.; ROY, D. P.; BOSCHETTI, L.; ZHANG, H. K.; YAN, L.; KUMAR, S. S.; GOMEZ-DANS, J.; LI, J. Separability analysis of Sentinel-2a multi-spectral instrument (MSI) data for burned area discrimination. **Remote Sensing**, v. 8, n. 10, 2016.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

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

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual técnico da vegetação brasileira**. 2.ed. Rio de Janeiro: IBGE, 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Mapa de biomas do Brasil**, primeira aproximação. Rio de Janeiro: IBGE, 2004. Disponível em: < www.ibge.gov.br>. Acesso em: jan. 2017.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Programa queimadas: área queimada por biomas**. 2017. Disponível em: < <https://prodwww-queimadas.dgi.inpe.br/aq1km/>>. Acesso em: jan. 2017.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. Banco de dados do programa de monitoramento de queimadas. Disponível em: <www.dpi.inpe.br/proarco/bdqueimadas>. Acesso em: mar. 2016.

JIMÉNEZ-MUÑOZ, J. C.; MATTAR, C.; BARICHIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J. A.; SCHRIER, G. VAN DER. Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015–2016. **Scientific Reports**, v. 6, p. 33130, Sept. 2016.

KATAGIS, T.; GITAS, I.; MITRI, G. An object-based approach for fire history reconstruction by using three generations of landsat sensors. **Remote Sensing**, v. 6, n. 6, p. 5480–5496, 2014.

KAUFMAN, Y. J.; REMER, L. A. Detection of forests using Mid-IR reflectance: an application for aerosol studies. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 3, p. 672–683, 1994.

KEY, C.H.; BENSON, N.C. Landscape assessment: ground measure of severity, the composite burn index, and remote sensing of severity, the normalized burn index. In: LUTES, D.; KEANE, R.; CARATTI, J.; KEY, C.H.; BENSON, N.C.; SUTHERLAND, S.; GANGI, L. (Eds). **FIREMON: Fire Effects Monitoring and Inventory System**. Fort Collins, CO: USDA Forest Service, 2005.

KÖRTING, T. S. **GeoDMA** : a toolbox integrating data mining with object-based and multi-temporal analysis of satellite. 2012. 123p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

KÖRTING, T. S.; GARCIA FONSECA, L. M.; CÂMARA, G. GeoDMA-geographic data mining analyst. **Computers and Geosciences**, v. 57, p. 133–145, 2013.

KUMAR, V.; MINZ, S. Feature selection: a literature review. **The Smart Computing Review**, v. 4, n. 3, 2014.

LANORTE, A.; DANESE, M.; LASAPONARA, R.; MURGANTE, B. Multiscale mapping of burn area and severity using multisensor satellite data and spatial autocorrelation analysis. **International Journal of Applied Earth Observation and Geoinformation**, v. 20, p. 42–51, fev. 2013.

LARIS, P. S. Spatiotemporal problems with detecting and mapping mosaic fire regimes with coarse-resolution satellite data in Savanna environments. **Remote Sensing of Environment**, v. 99, p. 412–424, 2005.

LAROSE, D. T.; LAROSE, C. D. **Discovering knowledge in data**: an introduction to data mining. 2 ed. New Jersey: John Wiley and Sons, 2014. 316p.

LASAPONARA, R. Estimating spectral separability of satellite derived parameters for burned areas mapping in the Calabria region by using SPOT-Vegetation data. **Ecological Modelling**, v. 196, n. 1–2, p. 265–270, 2006.

LATORRE, M. L.; CARVALHO JUNIOR, O. A.; SANTOS, J. R.; SHIMABUKURO, Y. E. Integração de dados de sensoriamento remoto multi resoluções para a representação da cobertura da terra utilizando campos contínuos de vegetação e classificação por árvores de decisão. **Revista Brasileira de Geofísica**, v. 25, n. 1, p. 63–74, 2007.

LENTILE, L. B.; HOLDEN, Z. A.; SMITH, A. M. S.; FALKOWSKI, M. J.; HUDAK, A. T.; MORGAN, P.; LEWIS, S. A.; GESSLER, P. E.; BENSON, N. C. Remote sensing techniques to

assess active fire characteristics and post-fire effects. **International Journal of Wildland Fire**, v. 15, n. 3, p. 319–345, 2006.

LI, M.; MA, L.; BLASCHKE, T.; CHENG, L.; TIEDE, D. A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. **International Journal of Applied Earth Observation and Geoinformation**, v. 49, p. 87-98, 2016.

LIBONATI, R.; DACAMARA, C. C.; PEREIRA, J. M. C.; PERES, L. F. Retrieving middle-infrared reflectance using physical and empirical approaches: implications for burned area monitoring. . **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 1, p. 281–294, 2012.

LIBONATI, R.; DACAMARA, C. C.; SETZER, A. W.; MORELLI, F.; MELCHIORI, A. E. An algorithm for burned area detection in the Brazilian Cerrado using 4 μm MODIS imagery. **Remote Sensing**, v. 7, n. 11, p. 15782–15803, 2015.

LIMA, A. **Influência da cobertura da terra na extensão e configuração espacial de áreas queimadas em anos de seca extrema na Amazônia**. 2013. 90p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

LIMA, A.; SILVA, T. S. F.; DE ARAGÃO, L. E. O. E. C.; DE FEITAS, R. M.; ADAMI, M.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Land use and land cover changes determine the spatial relationship between fire and deforestation in the Brazilian Amazon. **Applied Geography**, v. 34, p. 239–246, 2012.

MA, L.; LI, M.; MA, X.; CHENG, L.; DU, P.; LIU, Y. A review of supervised object-based land-cover image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 277–293, 2017.

MAIN-KNORN, M.; PFLUG, B.; DEBAECKER, V.; LOUIS, J. Calibration and validation plan for the 12A processor and products of the Sentinel-2 mission. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 40, n. 7W3, p. 1249–1255, 2015.

MANDANICI, E.; BITELLI, G. Preliminary comparison of Sentinel-2 and Landsat-8 imagery for a combined use. **Remote Sensing**, v. 8, n. 12, 2016.

MAPBIOMAS. **Série anual de mapas de cobertura e uso de solo do Brasil**. Disponível em: <<http://mapbiomas.org/>>. Acesso em: dez. 2017.

MARTÍN, M. P.; GÓMEZ, I.; CHUVIECO, E. Burnt Area Index (BAIM) for burned area discrimination at regional scale using MODIS data. **Forest Ecology and Management**, v. 234, p. S221, 2006.

MELCHIORI, A. E.; DE, P.; CÂNDIDO, A.; LIBONATI, R.; MORELLI, F.; SETZER, A. W.; CRISTINA DE JESUS, S.; MARIA, L.; FONSECA, G.; KÖRTING, T. S. Spectral indices and multi-temporal change image detection algorithms for burned area extraction in the Brazilian Cerrado. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. 2015, João Pessoa. **Anais...** INPE, 2015. p.643-650. Disponível em: <http://queimadas.cptec.inpe.br/~rqueimadas/documentos/2015_Melchiori_etal_SpectralIndices_XVIISBSR.pdf>. Acesso em: 1 out. 2017.

MIETTINEN, J.; HYER, E.; CHIA, A. S.; KWOH, L. K.; LIEW, S. C. Detection of vegetation fires and burnt areas by remote sensing in insular Southeast Asian conditions: current status of knowledge and future challenges. **International Journal of Remote Sensing**, v. 34, n. 12, p. 4344–4366, 2013.

MITRAKIS, N. E.; MALLINIS, G.; KOUTSIAS, N.; THEOCHARIS, J. B. Burned area mapping in Mediterranean environment using medium-resolution multi-spectral data and a neuro-fuzzy classifier. **International Journal of Image and Data Fusion**, v. 3, n. 4, p. 299–318, 2012.

MITRI, G. H.; GITAS, I. Z. A semi-automated object-oriented model for burned area mapping in the Mediterranean region using Landsat-TM imagery. **International Journal of Wildland Fire**, v. 13, n. 3, p. 367–376, 2004.

MORTON, D. C.; DEFRIES, R. S.; NAGOL, J.; SOUZA, C. M.; KASISCHKE, E. S.; HURTT, G. C.; DUBAYAH, R. Mapping canopy damage from understory fires in amazon forests using annual time series of Landsat and MODIS data. **Remote Sensing of Environment**, v. 115, n. 7, p. 1706–1720, 2011.

MORTON, D. C.; LE PAGE, Y.; DEFRIES, R.; COLLATZ, G. J.; HURTT, G. C. Understory fire frequency and the fate of burned forests in southern Amazonia. **Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences**, v. 368, n. 1619, p. 20120163, 2013.

MOUILLOT, F.; SCHULTZ, M. G.; YUE, C.; CADULE, P.; TANSEY, K.; CIAIS, P.; CHUVIECO, E. Ten years of global burned area products from spaceborne remote sensing—a review: analysis of user needs and recommendations for future developments. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, n. 1, p. 64–79, 2014.

MOUSIVAND, A.; MENENTI, M.; GORTE, B.; VERHOEF, W. Multi-temporal, multi-sensor retrieval of terrestrial vegetation properties from spectral–directional radiometric data. **Remote Sensing of Environment**, v. 158, p. 311–330, mar. 2015.

MÜLLER-WILM, U. Sentinel-2 MSI – level-2A prototype processor installation and user manual. **European Space Agency, (Special Publication) ESA SP**, v. 49, n. 2.2, p. 1–51, 2016.

NAMIKAWA, L. M.; KÖRTING, T. S.; CASTEJON, E. F. Water body extraction from Rapideye images: an automated methodology based on Hue component of color transformation from RGB to HSV model. **Revista Brasileira de Cartografia**, v. 68, n. 6, p. 1097–1111, 2016.

NEVES, A. K. **Mineração de dados de sensoriamento remoto para detecção e classificação de áreas de pastagem na Amazônia Legal**. 2017. 77p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

NOBRE, C. A.; OBREGÓN, G. O.; MARENGO, J. A.; FU, R.; POVEDA, G. Characteristics of Amazonian climate: main features. **Amazonia and Global Change, Geophysical Monograph Series**, 186, 2009.

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

OLIVA, P.; SCHROEDER, W. Assessment of VIIRS 375m active fire detection product for direct burned area mapping. **Remote Sensing of Environment**, v. 160, p. 144–155, 2015.

- PADILLA, M.; OLOFSSON, P.; STEHMAN, S. V.; TANSEY, K.; CHUVIECO, E. Stratification and sample allocation for reference burned area data. **Remote Sensing of Environment**, v. 203, p. 240–255, 2017.
- PADILLA, M.; STEHMAN, S. V.; RAMO, R.; CORTI, D.; HANTSON, S.; OLIVA, P.; ALONSO-CANAS, I.; BRADLEY, A. V.; TANSEY, K.; MOTA, B.; PEREIRA, J. M.; CHUVIECO, E. Comparing the accuracies of remote sensing global burned area products using stratified random sampling and estimation. **Remote Sensing of Environment**, v. 160, p. 114–121, 2015.
- PEREIRA, A. A.; TEIXEIRA, F. R.; LIBONATI, R.; MELCHIORI, E. A.; MARCELO, L.; CARVALHO, T. Evaluation of spectral indices for burned area identification in Cerrado using Landsat TM data. **Revista Brasileira de Cartografia**, v. 68, n. 8, p. 1665–1680, 2016.
- PEREIRA, J. M. C. A comparative evaluation of NOAA/AVHRR vegetation indexes for burned surface detection and mapping. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 1, p. 217–226, 1999.
- PEREIRA, M. C.; SETZER, A W. Spectral characteristics of fire scars in Landsat-5TM images of Amazonia. **International Journal of Remote Sensing**, v. 14, n. 11, p. 2061–2078, 1993.
- PINHO, C. M. D.; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C. M.; KUX, H. J. H. Land-cover classification of an intra- urban environment using high- resolution images and object-based image analysis. **International Journal of Remote Sensing**, v. 33, p. 5973–5995, 2012.
- PINTO, C.; PONZONI, F.; CASTRO, R.; LEIGH, L.; MISHRA, N.; AARON, D.; HELDER, D. First in-flight radiometric calibration of MUX and WFI on-board CBERS-4. **Remote Sensing**, v. 8, n. 5, 2016.
- PIROMAL, R. A. S.; RIVERA-LOMBARDI, R. J.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; KRUG, T. Utilização de dados MODIS para a detecção de queimadas na Amazônia. **Acta Amazonica**, v. 38, n. 1, p. 77–84, 2008.
- PIVELLO, V. R. The use of fire in the Cerrado and Amazonian rainforests of Brazil: past and present. **Fire Ecology**, v. 7, n. 1, p. 24–39, 2011.
- POLYCHRONAKI, A.; GITAS, I. Z. Burned area mapping in greece using SPOT-4 HRVIR images and object-based image analysis. **Remote Sensing**, v. 4, n. 2, p. 424–438, 2012.
- PONTIUS, R. G.; MILLONES, M. Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011.
- QUINLAN, J. R. **C4.5**: program for machine learning. San Mateo: Morgan Kaufmann , 1993.
- R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2017. Disponível em: <<https://www.r-project.org>>.
- RADOUX, J.; CHOMÉ, G.; JACQUES, D. C.; WALDNER, F.; BELLEMANS, N.; MATTON, N.; LAMARCHE, C.; D’ANDRIMONT, R.; DEFOURNY, P. Sentinel-2’s potential for sub-pixel landscape feature detection. **Remote Sensing**, v. 8, n. 6, 2016.
- RIVERA-LOMBARDI, R.; KRUG, T.; SETZER, A. **Estimativa de áreas queimadas com produtos MODIS como subsídio à estimativa de emissões de gases de efeito estufa pela queima de biomassa na Amazônia e Cerrado brasileiros**. 2009. 174p. Tese (Doutorado em

Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

ROUSE, J.W.; HAAS, R.H.; SCHELL J. A.; DEERING, D.W. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3, Washington, D.C., 1973. **Proceedings...** Washington, D.C.: NASA Goddard Space Flight Center, 1973. v.1, p.309-317. (NASA SP-351).

ROY, D. P.; BOSCHETTI, L.; JUSTICE, C. O.; JU, J. The collection 5 MODIS burned area product - global evaluation by comparison with the MODIS active fire product. **Remote Sensing of Environment**, v. 112, n. 9, p. 3690–3707, 2008.

SCHEPERS, L.; HAEST, B.; VERAVERBEKE, S.; SPANHOVE, T.; BORRE, J. VANDEN; GOOSSENS, R. Burned area detection and burn severity assessment of a heathland fire in Belgium using Airborne Imaging Spectroscopy (APEX). **Remote Sensing**, v. 6, n. 3, p. 1803–1826, 2014.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. Amsterdam: Elsevier, 2007. 515p.

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, n. 6, p. 1537–1546, 2009.

SHIMABUKURO, Y. E.; MIETTINEN, J.; BEUCHLE, R.; GRECCHI, R. C.; SIMONETTI, D.; ACHARD, F. Estimating burned area in Mato Grosso, Brazil, using an object-based classification method on a systematic sample of medium resolution satellite images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 9, p. 4502–4508, 2015.

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

SILVA JUNIOR, C. H. L.; ARAGÃO, L. E. O. C.; ANDERSON, L. O.; PENHA, T. V. Mapeamento de queimadas na Amazônia Legal brasileira utilizando dados MODIS e VIIRS: resultados preliminares. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18. 2017 Santos. **Anais...** INPE, 2017. .3475-3482. Disponível em: < <http://marte2.sid.inpe.br/rep/sid.inpe.br/marte2/2017/10.27.13.11>>. Acesso em: 1 out. 2017.

SILVA, M. P. S.; CÂMARA, G.; ESCADA, M. I. S.; DE SOUZA, R. C. M. Remote sensing image mining: detecting agents of land use change in tropical forest areas. **International Journal of Remote Sensing**, v.29, n.16, p.4803–4822, 2008.

SILVA, S. S.; ALENCAR, A. A. C.; MENDOZA, E. R. H.; L. O.; BROWN, F. Dinâmica dos incêndios florestais no estado do Acre nas décadas de 90 e 00. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16, 2013, Foz do Iguaçu. **Anais...** INPE, 2013. p. 8799–8806. Disponível em:< <http://www.dsr.inpe.br/sbsr2013/files/p1510.pdf>>. Acesso em: 1 out. 2017.

SMITH, A M. S.; DRAKE, N. A; WOOSTER, M. J.; HUDAK, A T.; HOLDEN, Z. A; GIBBONS, C. J. Production of Landsat ETM+ reference imagery of burned areas within southern African savannahs: comparison of methods and application to MODIS. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2753–2775, 2007.

- SMITH, L. T.; ARAGÃO, L. E. O. C.; SABEL, C. E.; NAKAYA, T. Drought impacts on children's respiratory health in the Brazilian Amazon. **Scientific Reports**, v. 4, p. 3726, 2014.
- TAN, P.; STEINBACH, M.; KUMAR, V. Finding spatio-temporal patterns in earth science data. **Earth Science**, p. 1–12, 2001.
- TANG, S. J.; ALELYANI, H. L. "Feature selection for classification: a review," In: AGGARWAL, C. C. (Ed). **Data classification: algorithms and applications**. New York: CRC Press, 2013. p. 37-64.
- TRIGG, S.; FLASSE, S. An evaluation of different bi-spectral spaces for discriminating burned. **International Journal of Remote Sensing**, v. 22, n. 13, p. 2641–2647, 2001.
- TRIMBLE. **eCognition Developer 9.0**: reference book. Munique: Trimble Germany GmbH, 2014.
- VAN DER WERF, G. R.; RANDERSON, J. T.; GIGLIO, L.; COLLATZ, G. J.; MU, M.; KASIBHATLA, P. S.; MORTON, D. C.; DEFRIES, R. S.; JIN, Y.; VAN LEEUWEN, T. T. Global fire emissions and the contribution of deforestation, savanna, forest, agricultural, and peat fires (1997-2009). **Atmospheric Chemistry and Physics**, v. 10, n. 23, p. 11707–11735, 2010.
- VEDOVATO, L. B.; JACON, A. D.; PESSÔA, A. C. M.; LIMA, A.; ARAGÃO, L. E. O. E. C. Detection of burned forests in Amazonia using the Normalized Burn Ratio (NBR) and Linear Spectral Mixture Model from Landsat 8 images. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17, 2015, João Pessoa. **Anais... INPE**, 2015. p. 2984–2991. Disponível em: < <http://www.dsr.inpe.br/sbsr2015/files/p0594.pdf> >. Acesso em: 1 out. 2017.
- VEENENDAAL, E. M.; VEENENDAAL, E. M.; TORELLO-RAVENTOS, M.; FELDPAUSCH, T. R.; DOMINGUES, T. F.; GERARD, F.; SCHRODT, F.; SAIZ, G.; QUESADA, C. A.; DJAGBLETEY, G.; FORD, A.; KEMP, J.; MARIMON, B. S.; MARIMON-JUNIOR, B. H.; LENZA, E.; RATTER, J. A.; MARACAHIPES, L.; SASAKI, D.; SONKÉ, B.; ZAPFACK, L.; VILLARROEL, D.; SCHWARZ, M.; YOKO ISHIDA, F.; GILPIN, M.; NARDOTO, G. B.; AFFUM-BAFFOE, K.; ARROYO, L.; BLOOMFIELD, K.; CECA, G.; COMPAORE, H.; DAVIES, K.; DIALLO, A.; FYLLAS, N. M.; GIGNOUX, J.; HIEN, F.; JOHNSON, M.; MOUGIN, E.; HIERNAUX, P.; KILLEEN, T.; METCALFE, D.; MIRANDA, H. S.; STEININGER, M.; SYKORA, K.; BIRD, M. I.; GRACE, J.; LEWIS, S.; PHILLIPS, O. L.; LLOYD, J. Structural, physiognomic and above-ground biomass variation in savanna-forest transition zones on three continents - how different are co-occurring savanna and forest formations? **Biogeosciences**, v. 12, n. 10, p. 2927–2951, 2015.
- VERAVERBEKE, S.; HARRIS, S.; HOOK, S. Evaluating spectral indices for burned area discrimination using MODIS/ASTER (MASTER) airborne simulator data. **Remote Sensing of Environment**, v. 115, n. 10, p. 2702–2709, 2011.
- VERMOTE, E. F.; TANRÉ, D.; DEUZÉ, J. L.; HERMAN, M.; MORCRETTE, J. J. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 675–686, 1997.
- VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 2016.
- WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. **Data mining: practical machine learning tools and techniques**. San Mateo: Morgan Kaufmann, 2016.

WU, X.; KUMAR, V.; QUINLAN, J. R.; GHOSH, J.; YANG, Q.; MOTODA, H.; MCLACHLAN, G. J.; NG, A.; LIU, B.; YU, P. S.; MICHAEL, Z. Z.; DAVID, S.; DAN, J. H. Top 10 algorithms in data mining. **Knowledge Information Systems**, v. 14, p.1-37, 2008.

WULDER, M. A.; MASEK, J. G.; COHEN, W. B.; LOVELAND, T. R.; WOODCOCK, C. E. Opening the archive: how free data has enabled the science and monitoring promise of Landsat. **Remote Sensing of Environment**, v. 122, p. 2–10, jul. 2012.

YAN, L.; ROY, D.; ZHANG, H.; LI, J.; HUANG, H. An automated approach for sub-pixel registration of Landsat-8 Operational Land Imager (OLI) and Sentinel-2 Multi Spectral Instrument (MSI) imagery. **Remote Sensing**, v. 8, n. 6, 2016.

YUAN, D.; ELVIDGE, C. D. Comparison of relative radiometric normalization techniques. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 51, p.117–126, 1996.

ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v.159, p.269-277, 2015.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v.118, p.83-94, 2012.

APÊNDICE A - DINÂMICA PROGRESSIVA DE TESTES DE VALORES DOS PARÂMETROS DE SEGMENTAÇÃO

Tabela A.1 - Dinâmica progressiva para determinação empírica dos parâmetros de segmentação.

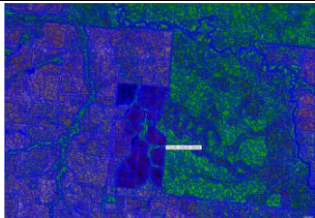
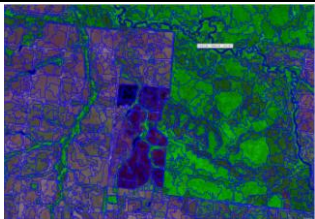
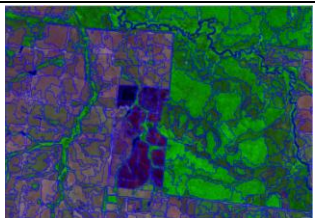
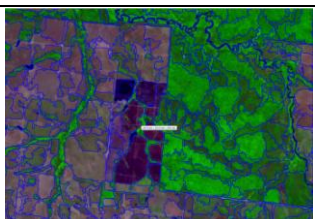
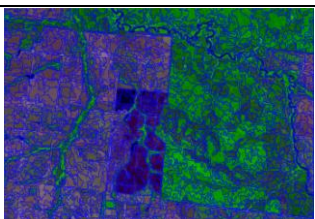
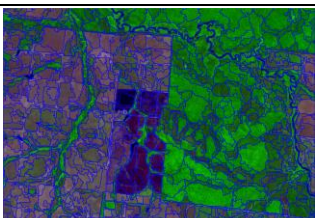
API – OLI													
Escala	Critérios de Homogeneidade		Peso das Camadas								Número de Segmentos	Observações	
	Forma	Compacidade	B1	B2	B3	B4	B5	B6	B7	B8			
10	0,5	0,5	1	1	1	1	1	1	1	1	1	980.597	Apenas o fator escala é alterado. Hipersegmentação da imagem. Objetos muito pequenos gerados com pouquíssima representatividade das classes alvo. Áreas queimadas muito fracionadas e segmentadas.
30	0,5	0,5	1	1	1	1	1	1	1	1	1	131.579	Supersegmentação da imagem. Objetos de tamanho pequeno com alguma representatividade das classes alvo. Rios, floresta e áreas queimadas muito segmentadas e pouco bem definidas. No entanto, boa separabilidade entre as classes alvo. Dentre os testes com as bandas de mesmo peso é a melhor configuração do fator escala.
50	0,5	0,5	1	1	1	1	1	1	1	1	1	61.429	Objetos um pouco maiores, mas ainda pequenos. Quantidade de objetos criados diminui consideravelmente. Agrupamento dos segmentos não permite a identificação ideal da maioria das classes alvo.
80	0,5	0,5	1	1	1	1	1	1	1	1	1	40.003	Objetos médios gerados. Número de novos objetos criados diminui. Áreas queimadas pouco delimitadas e formas muito regulares. Rios e floresta pouco representativos.
100	0,5	0,5	1	1	1	1	1	1	1	1	1	36.620	Número de novos objetos criados diminui. Objetos de tamanho médio gerados com pouca representatividade das classes alvo. Áreas queimadas pouco delimitadas e formas muito regulares. Rios e floresta pouco representativos. Fator de escala superior a este valor gera superobjetos.

(Continua).

Tabela A.1 – Continuação.

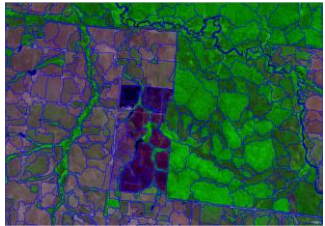
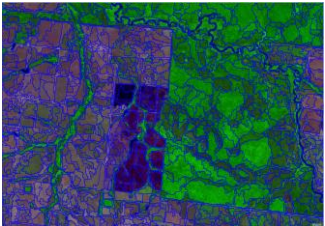
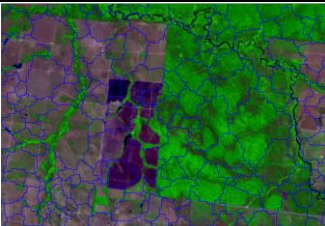
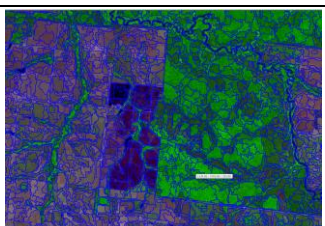
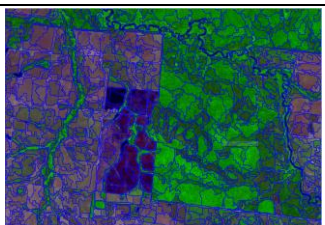
30	0,1	0,5	1	1	1	1	1	1	1	1	203.814	Apenas o fator forma é alterado. Objetos muito regulares com pouquíssima representatividade das classes alvo. Número de novos objetos criados aumenta. Objetos muito compactos e regulares.
30	0,7	0,5	1	1	1	1	1	1	1	1	94.074	Objetos pouco regulares, mas com boa representatividade das classes alvo. Número de novos objetos criados diminui. Objetos melhor delimitados tanto nas áreas queimadas quanto em florestas e rios. Melhor configuração para o fator forma e escala considerando o mesmo peso para todas as bandas.
30	0,9	0,5	1	1	1	1	1	1	1	1	50.267	Objetos bem definidos e regulares. Delimitação ruim de alvos contínuos como rios. Número de novos objetos criados diminui consideravelmente. Aumentar o peso do fator forma favorece o peso da forma dos objetos.
30	0,7	0,5	1	1	1	1	1	1	0	0	100.329	Apenas as bandas multiespectrais recebem peso. Número de novos objetos criados aumenta. Pouca alteração observada na representatividade de classes, objetos antes médios são particionados em novos segmentos.
30	0,7	0,5	0	0	0	0	0	0	1	1	1.364	Apenas as bandas índices recebem peso. Número de objetos muito baixo. Nenhuma representatividade das classes ao isolar as bandas índices. É preciso reduzir o fator de escala para observar mudanças na segmentação.
30	0,7	0,5	0	0	0	1	1	1	0	0	142.573	Apenas as bandas multiespectrais NIR e SWIR recebem peso. Supersegmentação da imagem. Número elevado de objetos criados. Pouca delimitação das classes alvos, porém boa representatividade dos alvos com resposta espectral alta nestas bandas.
30	0,7	0,5	1	1	1	3	3	3	2	2	110.660	As bandas multiespectrais e os índices são combinados de forma a favorecer a delimitação das áreas queimadas. Supersegmentação da imagem. Pouca variação no número de objetos criados em relação à segmentação com as bandas de mesmo peso. Boa delimitação das classes alvo em geral. Delimitam da melhor forma possível as áreas queimadas bem como as florestas, rios, pastagem, etc. Configuração adotada. Fim dos testes.

Tabela A.2 - Lógica progressiva para determinação empírica dos parâmetros de segmentação.

Escala	Critérios de Homogeneidade		Peso das Camadas								Número de Segmentos	Resultado Produzido	
	Forma	Compacidade	B1	B2	B3	B4	B5	B6	B7	B8			
10	0,5	0,5	1	1	1	1	1	1	1	1	1	980,597	
30	0,5	0,5	1	1	1	1	1	1	1	1	1	131,579	
50	0,5	0,5	1	1	1	1	1	1	1	1	1	61,429	
100	0,5	0,5	1	1	1	1	1	1	1	1	1	36,620	
30	0,1	0,5	1	1	1	1	1	1	1	1	1	203,814	
30	0,7	0,5	1	1	1	1	1	1	1	1	1	94,074	

(Continua).

Tabela A.2 – Continuação.

30	0,9	0,5	1	1	1	1	1	1	1	1	50,267	
30	0,7	0,5	1	1	1	1	1	1	0	0	100,329	
30	0,7	0,5	0	0	0	0	0	0	1	1	1,364	
30	0,7	0,5	0	0	0	1	1	1	0	0	142,573	
30	0,7	0,5	1	1	1	3	3	3	2	2	110,660	

APÊNDICE B - MATRIZES DE CONFUSÃO DAS ETAPAS DE TESTE DE LIMIARES E DO MODELO REFINADO DE DETECÇÃO DE ÁREAS QUEIMADAS

Tabela B.1- Matrizes de confusão para o teste de limiares BAI na AP1.

Valor de Limiar (1.0 σ)					Valor de Limiar (1.0 σ)						
Landsat-8 OLI					Sentinel-2 MSI						
A	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)	D	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)		
	Áreas Queimadas	Áreas Não Queimadas				Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	129,08	48,04	177,12	72,88	BAI	Áreas Queimadas	124,68	308,38	433,06	28,79
	Áreas Não Queimadas	65,34	10675,33	10740,67	99,39		Áreas Não Queimadas	61,62	10609,38	10671,00	99,42
	Total (Km ²)	194,42	10723,37	10917,79			Total (Km ²)	186,30	10917,76	11104,06	
	Acurácia do Produtor (%)	66,39	99,55	Exatidão Global	98,96		Acurácia do Produtor (%)	66,92	97,18	Exatidão Global	96,67
	Erros de Omissão	0,34		Coefficiente Dice	0,69		Erros de Omissão	0,33		Coefficiente Dice	0,40
	Erros de Comissão	0,27		Erro Relativo	47,70		Erros de Comissão	0,71		Erro Relativo	308,05
Valor de Limiar (1.5 σ)					Valor de Limiar (1.5 σ)						
Landsat-8 OLI					Sentinel-2 MSI						
B	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)	E	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)		
	Áreas Queimadas	Áreas Não Queimadas				Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	163,80	138,25	302,05	54,23	BAI	Áreas Queimadas	143,39	369,74	513,13	27,94
	Áreas Não Queimadas	30,62	10585,12	10615,74	99,71		Áreas Não Queimadas	42,91	10548,02	10590,93	99,59
	Total (Km ²)	194,42	10723,37	10917,79			Total (Km ²)	186,30	10917,76	11104,06	
	Acurácia do Produtor (%)	84,25	98,71	Exatidão Global	98,45		Acurácia do Produtor (%)	76,97	96,61	Exatidão Global	96,28
	Erros de Omissão	0,16		Coefficiente Dice	0,66		Erros de Omissão	0,23		Coefficiente Dice	0,41
	Erros de Comissão	0,46		Erro Relativo	138,09		Erros de Comissão	0,72		Erro Relativo	369,51
Valor de Limiar (2.0 σ)					Valor de Limiar (2.0 σ)						
Landsat-8 OLI					Sentinel-2 MSI						
C	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)	F	Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)		
	Áreas Queimadas	Áreas Não Queimadas				Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	181,16	373,41	554,57	32,67	BAI	Áreas Queimadas	157,82	469,17	626,99	25,17
	Áreas Não Queimadas	13,26	10349,96	10363,22	99,87		Áreas Não Queimadas	28,48	10448,59	10477,07	99,73
	Total (Km ²)	194,42	10723,37	10917,79			Total (Km ²)	186,30	10917,76	11104,06	
	Acurácia do Produtor (%)	93,18	96,52	Exatidão Global	96,46		Acurácia do Produtor (%)	84,71	95,70	Exatidão Global	95,52
	Erros de Omissão	0,07		Coefficiente Dice	0,48		Erros de Omissão	0,15		Coefficiente Dice	0,39
	Erros de Comissão	0,67		Erro Relativo	373,34		Erros de Comissão	0,75		Erro Relativo	469,02

Legenda: (A) Landsat-8 OLI +/- 1.0 σ , (B) Landsat-8 OLI +/- 1.5 σ , (C) Landsat-8 OLI +/- 2.0 σ , (D) Sentinel-2 MSI +/- 1.0 σ , (E) Sentinel-2 MSI +/- 1.5 σ , (F) Sentinel-2 MSI +/- 2.0 σ .

Tabela B.2 - Matrizes de confusão para o teste de limiares BAI na AP2.

A		Valor de Limiar (1.0 σ)			
		Landsat-8 OLI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	65,32	177,00	242,32	26,96
	Áreas Não Queimadas	34,08	10016,00	10050,08	99,66
	Total (Km ²)	99,40	10193,00	10292,40	
	Acurácia do Produtor (%)	65,71	98,26	Exatidão Global	97,95
	Erros de Omissão	0,34		Coefficiente Dice	0,38
	Erros de Comissão	0,73		Erro Relativo	176,66

B		Valor de Limiar (1.5 σ)			
		Landsat-8 OLI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	84,70	265,00	349,70	24,22
	Áreas Não Queimadas	14,70	9928,00	9942,70	99,85
	Total (Km ²)	99,40	10193,00	10292,40	
	Acurácia do Produtor (%)	85,21	97,40	Exatidão Global	97,28
	Erros de Omissão	0,15		Coefficiente Dice	0,38
	Erros de Comissão	0,76		Erro Relativo	264,85

C		Valor de Limiar (2.0 σ)			
		Landsat-8 OLI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	94,00	688,00	782,00	12,02
	Áreas Não Queimadas	5,40	9505,00	9510,40	99,94
	Total (Km ²)	99,40	10193,00	10292,40	
	Acurácia do Produtor (%)	94,57	93,25	Exatidão Global	93,26
	Erros de Omissão	0,05		Coefficiente Dice	0,21
	Erros de Comissão	0,88		Erro Relativo	687,95

D		Valor de Limiar (1.0 σ)			
		Sentinel-2 MSI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	65,52	48,00	113,52	57,72
	Áreas Não Queimadas	34,06	10008,00	10042,06	99,66
	Total (Km ²)	99,58	10056,00	10155,58	
	Acurácia do Produtor (%)	65,80	99,52	Exatidão Global	99,19
	Erros de Omissão	0,34		Coefficiente Dice	0,61
	Erros de Comissão	0,42		Erro Relativo	47,66

E		Valor de Limiar (1.5 σ)			
		Sentinel-2 MSI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	84,73	138,00	222,73	38,04
	Áreas Não Queimadas	14,85	9918,00	9932,85	99,85
	Total (Km ²)	99,58	10056,00	10155,58	
	Acurácia do Produtor (%)	85,09	98,63	Exatidão Global	98,49
	Erros de Omissão	0,15		Coefficiente Dice	0,53
	Erros de Comissão	0,62		Erro Relativo	137,85

F		Valor de Limiar (2.0 σ)			
		Sentinel-2 MSI			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	93,59	576,00	669,59	13,98
	Áreas Não Queimadas	5,99	9480,00	9485,99	99,94
	Total (Km ²)	99,58	10056,00	10155,58	
	Acurácia do Produtor (%)	93,98	94,27	Exatidão Global	94,27
	Erros de Omissão	0,06		Coefficiente Dice	0,24
	Erros de Comissão	0,86		Erro Relativo	575,94

Legenda: (A) Landsat-8 OLI +/- 1.0 σ , (B) Landsat-8 OLI +/- 1.5 σ , (C) Landsat-8 OLI +/- 2.0 σ , (D) Sentinel-2 MSI +/- 1.0 σ , (E) Sentinel-2 MSI +/- 1.5 σ , (F) Sentinel-2 MSI +/- 2.0 σ .

Tabela B.3 - Matrizes de confusão para os modelos refinados de detecção de áreas queimadas.

A		AP1 - Modelo de Detecção de Áreas Queimadas			
		OLI Landsat-8			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	136,09	39,10	175,19	77,68
	Áreas Não Queimadas	52,60	10102,70	10155,30	99,48
	Total (Km ²)	188,69	10141,80	10330,49	
	Acurácia do Produtor (%)	72,12	99,61	Exatidão Global	99,11
	Erros de Omissão	0,28		Coefficiente Dice	0,75
	Erros de Comissão	0,22		Erro Relativo	38,82

B		AP1 - Modelo de Detecção de Áreas Queimadas			
		MSI Sentinel-2			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	143,32	50,00	193,32	74,14
	Áreas Não Queimadas	31,67	9943,76	9975,43	99,68
	Total (Km ²)	174,99	9993,76	10168,75	
	Acurácia do Produtor (%)	81,90	99,50	Exatidão Global	99,20
	Erros de Omissão	0,18		Coefficiente Dice	0,78
	Erros de Comissão	0,26		Erro Relativo	49,82

C		AP2 - Modelo de Detecção de Áreas Queimadas			
		OLI Landsat-8			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	59,11	31,00	90,11	65,60
	Áreas Não Queimadas	30,28	9454,00	9484,28	99,68
	Total (Km ²)	89,39	9485,00	9574,39	
	Acurácia do Produtor (%)	66,13	99,67	Exatidão Global	99,36
	Erros de Omissão	0,34		Coefficiente Dice	0,66
	Erros de Comissão	0,34		Erro Relativo	30,66

D		AP2 - Modelo de Detecção de Áreas Queimadas			
		MSI Sentinel-2			
		Referência (Km ²)		Total (Km ²)	Acurácia do Usuário (%)
Áreas Queimadas	Áreas Não Queimadas				
BAI	Áreas Queimadas	74,19	66,00	140,19	52,92
	Áreas Não Queimadas	8,20	9378,00	9386,20	99,91
	Total (Km ²)	82,39	9444,00	9526,39	
	Acurácia do Produtor (%)	90,05	99,30	Exatidão Global	99,22
	Erros de Omissão	0,10		Coefficiente Dice	0,67
	Erros de Comissão	0,47		Erro Relativo	65,90

Legenda: (A) AP1 - Landsat-8 OLI (B) AP1 - Sentinel-2 MSI (C) AP2 - Landsat-8 OLI (D) AP2 - Sentinel-2 MSI.

APÊNDICE C - ÁRVORES DE DECISÃO GERADAS

A Tabela C orienta o leitor como guia para compreensão dos atributos escolhidos nos modelos de classificação.

Tabela C.1 - Nomes e siglas dos atributos.

Output Weka	Atributo	Tipo	Sigla
GLCM_Hom_1 GLCM_Hom_2	<i>GLCM Homogeneity BAI</i>	Espacial Textura	GLCM_Hom_BAI
GLCM_Ent_1 GLCM_Ent_2	<i>GLCM Entropy BAI</i>	Espacial Textura	GLCM_Ent_BAI
Mean_of_4 Mean_of_5	<i>Mean of outer border NIR</i>	Espectral Baseado em Pixel	Mean_OutB_NIR
GLCM_Cor_2	<i>GLCM Correlation MIRBI</i>	Espacial Textura	GLCM_Cor_MIRBI
Mean_of_in	<i>Mean_of_inner_border_MIRBI</i>	Espectral Baseado em Pixel	Mean_InB_MIRBI
Mean_of_8	<i>Mean of inner border BAI</i>	Espectral Baseado em Pixel	Mean_InB_BAI
Mean_of_11 Mean_of_17 Mean_of_13	<i>Mean of inner border NIR</i>	Espectral Baseado em Pixel	Mean_InB_NIR
Main_direc	<i>Main direction</i>	Espacial Forma	Main_direc
Max_pixel Max_pixel1	<i>Maximum of pixels MIRBI</i>	Espectral Baseado em Pixel	MaxPixel_MIRBI
quantile50 quantile51	<i>Quantile MIRBI</i>	Espectral Baseado em Objeto	Quantile_MIRBI
quantile54	<i>Quantile NIR</i>	Espectral Baseado em Objeto	Quantile_NIR
modeMinimu modeMini_2 modeMini_4	<i>Mode Minimum BAI</i>	Espectral Baseado em Objeto	Mode_Min_BAI
Mean_Layer	<i>Mean Layer BAI</i>	Espectral Baseado em Objeto	Mean_Layer_BAI
Ratio_La_1	<i>Ratio Layer MIRBI</i>	Espectral Baseado em Pixel	Ratio_Layer_MIRBI

(Continua).

Tabela C.1 - Continuação.

Output Weka	Atributo	Tipo	Sigla
Ratio_La_10	<i>Ratio Layer NDVI</i>	Espectral Baseado em Pixel	Ratio_Layer_NDVI
Contrast_5	<i>Contrast to neighbor pixels NIR</i>	Espectral Baseado em Pixel	Contrast_NIR
GLCM_Ang_4	<i>GLCM Angular 2nd moment BAI</i>	Espacial Textura	GLCM_Ang_BAI
modeMini_5	<i>Mode Minimum NIR</i>	Espectral Baseado em Objeto	Mode_Min_NIR
Circular_2 Circular_4	<i>Circular StdDev/Mean BAI</i>	Espectral Baseado em Pixel	Circular_S/M_BAI
Max_diff	<i>Maximum difference</i>	Espectral Baseado em Pixel	Max_diff
Mean_Lay_5	<i>Mean Layer NIR</i>	Espectral Baseado em Objeto	Mean_Layer_NIR
Skewness_2 Skewness_4	<i>Skewness BAI</i>	Espectral Baseado em Objeto	Skewness_BAI
Circular_1	<i>Circular StdDev/Mean MIRBI</i>	Espectral Baseado em Pixel	Circular_S/M_MIRBI
Elliptic_F	<i>Elliptic Fit</i>	Espectral Baseado em Pixel	Elliptic_Fit
Mean_of_4	<i>Mean of outer border BAI</i>	Espectral Baseado em Pixel	Mean_OutB_BAI
Skewness_8	<i>Skewness Blue</i>	Espectral Baseado em Objeto	Skewness_Blue
Circular_22	<i>Circular Mean NIR</i>	Espectral Baseado em Pixel	Circular_Mean_NIR
Ratio_La_7	<i>Ratio Layer Green</i>	Espectral Baseado em Pixel	Ratio_Layer_Green
Ratio_La_8	<i>Ratio Layer Blue</i>	Espectral Baseado em Pixel	Ratio_Layer_Blue

Figura C.1 - A árvore de decisão gerada pelo algoritmo J48 para AP1 - Landsat-8 OLI.

```
quantile54 <= 2007.5  
  
| Max_pixel_ <= 0.909101: Areas Nao Queimadas (69.0/7.0)  
  
| Max_pixel_ > 0.909101  
  
| | GLCM_Ent_1 <= 4.976953  
  
| | | Mean_of__4 <= 2434.327273  
  
| | | | Main_direc <= 1.010279  
  
| | | | | Mean_of_11 <= 1948.25  
  
| | | | | Max_pixel_ <= 0.998135: Areas Nao Queimadas (3.0)  
  
| | | | | Max_pixel_ > 0.998135  
  
| | | | | | Mean_of__8 <= 0.00094: Areas Nao Queimadas (11.0/5.0)  
  
| | | | | | Mean_of__8 > 0.00094: Areas Queimadas (14.0)  
  
| | | | | Mean_of_11 > 1948.25: Areas Nao Queimadas (12.0)  
  
| | | | Main_direc > 1.010279  
  
| | | | | quantile50 <= 0.896035  
  
| | | | | | GLCM_Ent_1 <= 4.657373  
  
| | | | | | GLCM_Cor_2 <= 0.626263: Areas Queimadas (62.0/12.0)  
  
| | | | | | GLCM_Cor_2 > 0.626263: Areas Nao Queimadas (4.0)  
  
| | | | | | GLCM_Ent_1 > 4.657373: Areas Nao Queimadas (8.0)  
  
| | | | | quantile50 > 0.896035  
  
| | | | | | Mean_of_11 <= 1882.108696: Areas Queimadas (1086.0/63.0)  
  
| | | | | | Mean_of_11 > 1882.108696  
  
| | | | | | GLCM_Ent_1 <= 2.867094: Areas Nao Queimadas (20.0/8.0)  
  
| | | | | | GLCM_Ent_1 > 2.867094  
  
| | | | | | | Mean_of__8 <= 0.12963
```

| | | | | | | | GLCM_Hom_1 <= 0.202918: Areas Queimadas (72.0/1.0)

| | | | | | | | GLCM_Hom_1 > 0.202918

| | | | | | | | Mean_of_11 <= 2027: Areas Queimadas (41.0/6.0)

| | | | | | | | Mean_of_11 > 2027: Areas Nao Queimadas (3.0)

| | | | | | | | Mean_of__8 > 0.12963: Areas Nao Queimadas (10.0/4.0)

| | | Mean_of__4 > 2434.327273

| | | | Mean_of_in <= 0.716421: Areas Nao Queimadas (12.0)

| | | | Mean_of_in > 0.716421

| | | | | Mean_of__4 <= 2678.957143: Areas Queimadas (29.0/9.0)

| | | | | Mean_of__4 > 2678.957143: Areas Nao Queimadas (8.0/1.0)

| | GLCM_Ent_1 > 4.976953

| | | quantile50 <= 0.929432: Areas Nao Queimadas (31.0)

| | | quantile50 > 0.929432

| | | | GLCM_Hom_1 <= 0.089796: Areas Queimadas (9.0)

| | | | GLCM_Hom_1 > 0.089796

| | | | | Mean_of_in <= 0.980738

| | | | | | GLCM_Cor_2 <= 0.596557

| | | | | | Mean_of__4 <= 2242.266667: Areas Queimadas (7.0)

| | | | | | Mean_of__4 > 2242.266667: Areas Nao Queimadas (3.0/1.0)

| | | | | | GLCM_Cor_2 > 0.596557: Areas Nao Queimadas (16.0/4.0)

| | | | | Mean_of_in > 0.980738: Areas Queimadas (7.0)

quantile54 > 2007.5

| Mean_of_in <= 0.803505: Areas Nao Queimadas (42366.0/51.0)

| Mean_of_in > 0.803505

| | Mean_of__4 <= 2510.439394

| | | Mean_of__4 <= 1860.454545

| | | GLCM_Ent_1 <= 2.896204: Areas Nao Queimadas (23.0/6.0)

| | | GLCM_Ent_1 > 2.896204: Areas Queimadas (83.0/13.0)

| | | Mean_of__4 > 1860.454545

| | | GLCM_Ent_1 <= 2.914077: Areas Nao Queimadas (54.0)

| | | GLCM_Ent_1 > 2.914077

| | | | GLCM_Cor_2 <= 0.464358

| | | | | Mean_of__4 <= 1956.25

| | | | | | GLCM_Ent_1 <= 3.522385: Areas Nao Queimadas (9.0/4.0)

| | | | | | GLCM_Ent_1 > 3.522385: Areas Queimadas (24.0/2.0)

| | | | | | Mean_of__4 > 1956.25

| | | | | | Main_direc <= 89.562652: Areas Nao Queimadas (20.0/4.0)

| | | | | | Main_direc > 89.562652: Areas Queimadas (31.0/12.0)

| | | | | GLCM_Cor_2 > 0.464358

| | | | | | Mean_of_in <= 0.935923: Areas Nao Queimadas (451.0/72.0)

| | | | | | Mean_of_in > 0.935923

| | | | | | Mean_of_11 <= 2334.445652

| | | | | | | GLCM_Hom_1 <= 0.029857: Areas Queimadas (13.0)

| | | | | | | GLCM_Hom_1 > 0.029857

| | | | | | | | GLCM_Cor_2 <= 0.796145

| | | | | | | | | quantile50 <= 0.997606: Areas Nao Queimadas (10.0/1.0)

| | | | | | | | | quantile50 > 0.997606: Areas Queimadas (36.0/17.0)

| | | | | | | | | GLCM_Cor_2 > 0.796145: Areas Queimadas (5.0)

| | | | | | | | | Mean_of_11 > 2334.445652: Areas Nao Queimadas (16.0/1.0)

| | | Mean_of__4 > 2510.439394: Areas Nao Queimadas (379.0/6.0)

Figura C.1- Continuação.

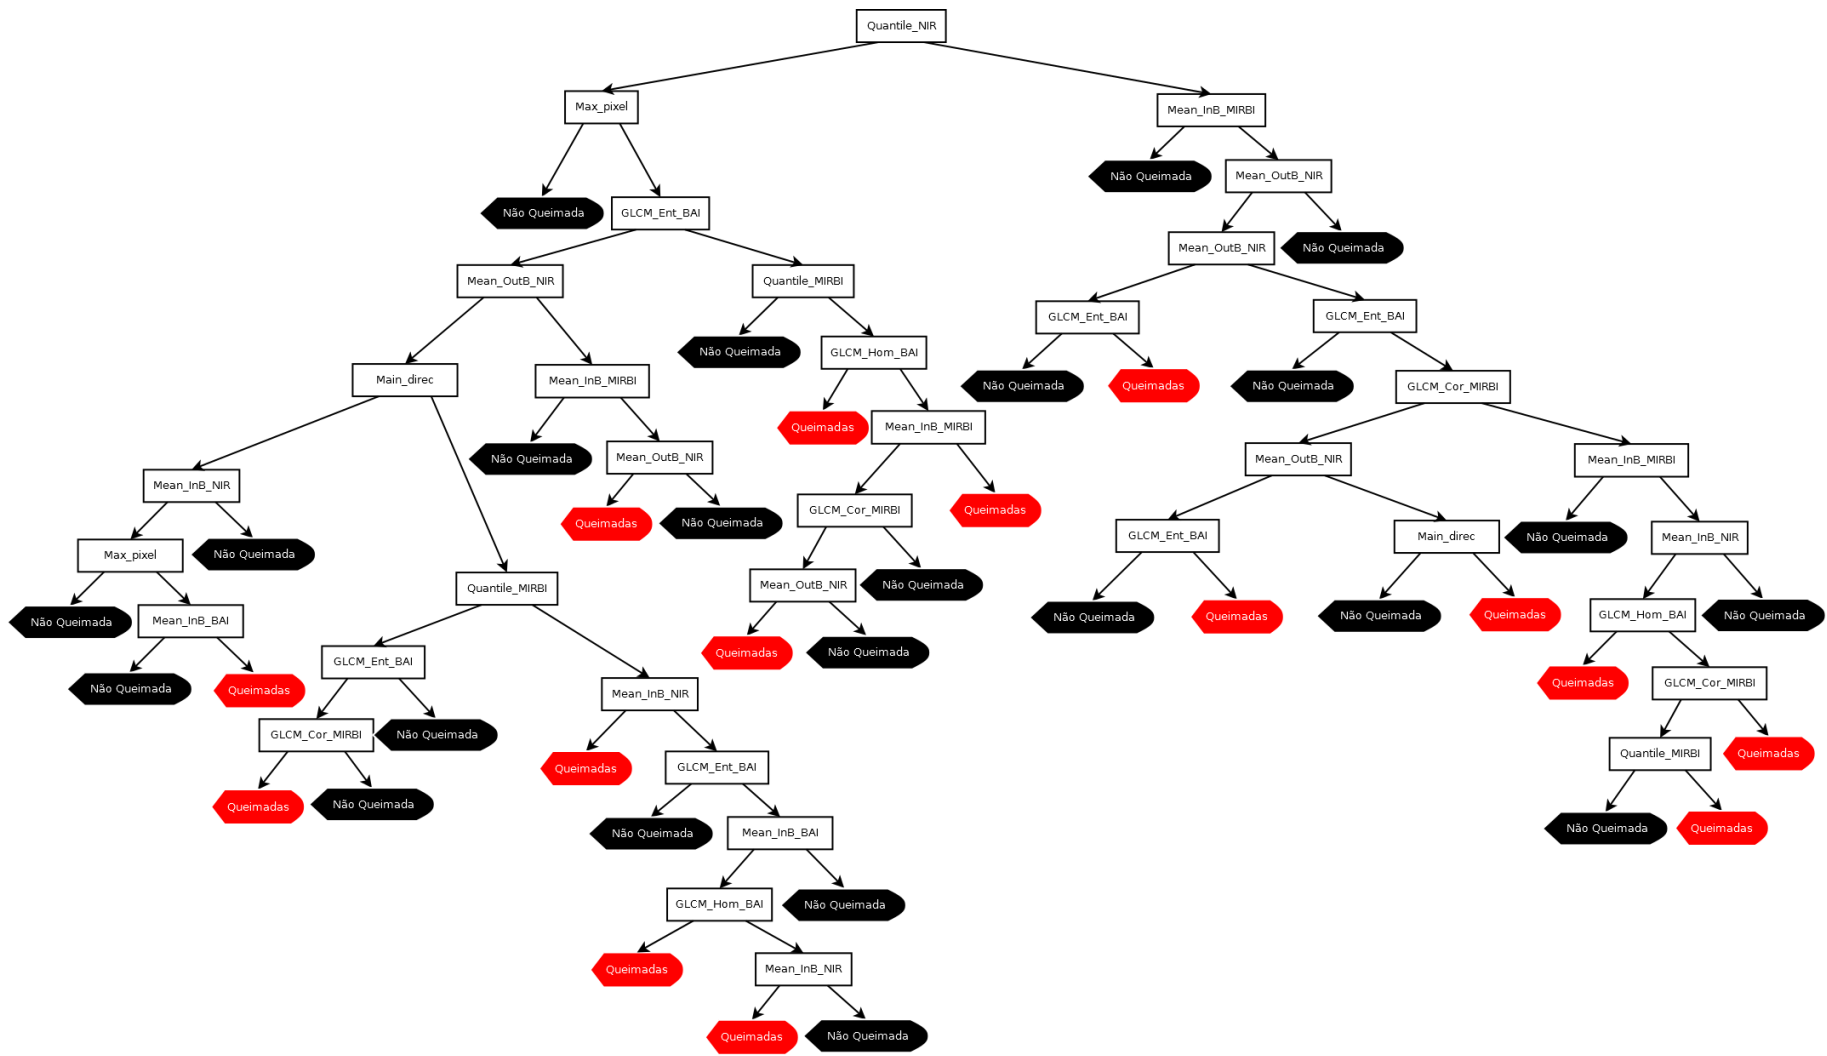


Figura C.2 - Árvore de decisão gerada pelo algoritmo J48 para AP1 – Sentinel-2 MSI.

Mean_of_in <= 0.749446: Areas Nao Queimadas (43329.0/44.0)

Mean_of_in > 0.749446

| Mean_of__4 <= 2311.56044

| | Mean_of__8 <= 0.156003

| | | GLCM_Cor_2 <= 0.675435

| | | | Mean_of__4 <= 1082.06

| | | | | Mean_of__8 <= 0.000363: Areas Nao Queimadas (30.0/5.0)

| | | | | Mean_of__8 > 0.000363

| | | | | | Mean_of_in <= 0.980608: Areas Nao Queimadas (6.0/2.0)

| | | | | | Mean_of_in > 0.980608: Areas Queimadas (10.0/1.0)

| | | | | | | Mean_of__4 > 1082.06

| | | | | | | modeMinimu <= 0.99941

| | | | | | | modeMinimu <= 0.735511

| | | | | | | | modeMinimu <= 0.651478

| | | | | | | | | Mean_of__4 <= 1769.063492: Areas Nao Queimadas (12.0/2.0)

| | | | | | | | | Mean_of__4 > 1769.063492

| | | | | | | | | | GLCM_Cor_2 <= 0.615448

| | | | | | | | | | | Mean_of__4 <= 2147.596154: Areas Queimadas (18.0)

| | | | | | | | | | | Mean_of__4 > 2147.596154: Areas Nao Queimadas (6.0/3.0)

| | | | | | | | | | | | GLCM_Cor_2 > 0.615448: Areas Nao Queimadas (7.0/2.0)

| | | | | | | | | | | | modeMinimu > 0.651478: Areas Queimadas (85.0/4.0)

| | | | | | | | | | | | modeMinimu > 0.735511

| | | | | | | | | | | | | Mean_of__4 <= 2013.702703: Areas Nao Queimadas (75.0/25.0)

| | | | | | | | | | | | | Mean_of__4 > 2013.702703: Areas Queimadas (28.0/5.0)

| | | | modeMinimu > 0.99941

| | | | | Mean_of_in <= 0.810567: Areas Nao Queimadas (25.0/10.0)

| | | | | Mean_of_in > 0.810567: Areas Queimadas (976.0/185.0)

| | | GLCM_Cor_2 > 0.675435

| | | | Mean_Layer <= 0.948231

| | | | | GLCM_Cor_2 <= 0.718009

| | | | | Mean_of_in <= 0.842526: Areas Nao Queimadas (13.0/1.0)

| | | | | Mean_of_in > 0.842526

| | | | | | Mean_of__4 <= 2045.555556: Areas Queimadas (6.0)

| | | | | | Mean_of__4 > 2045.555556: Areas Nao Queimadas (2.0/1.0)

| | | | | GLCM_Cor_2 > 0.718009: Areas Nao Queimadas (54.0/3.0)

| | | | Mean_Layer > 0.948231: Areas Queimadas (72.0/20.0)

| | Mean_of__8 > 0.156003

| | | Mean_of__4 <= 1887.614286: Areas Queimadas (146.0/48.0)

| | | Mean_of__4 > 1887.614286: Areas Nao Queimadas (397.0/100.0)

| Mean_of__4 > 2311.56044: Areas Nao Queimadas (441.0/26.0)

Número de folhas: 21

Tamanho da Árvore: 41

Figura C.2 – Continuação.

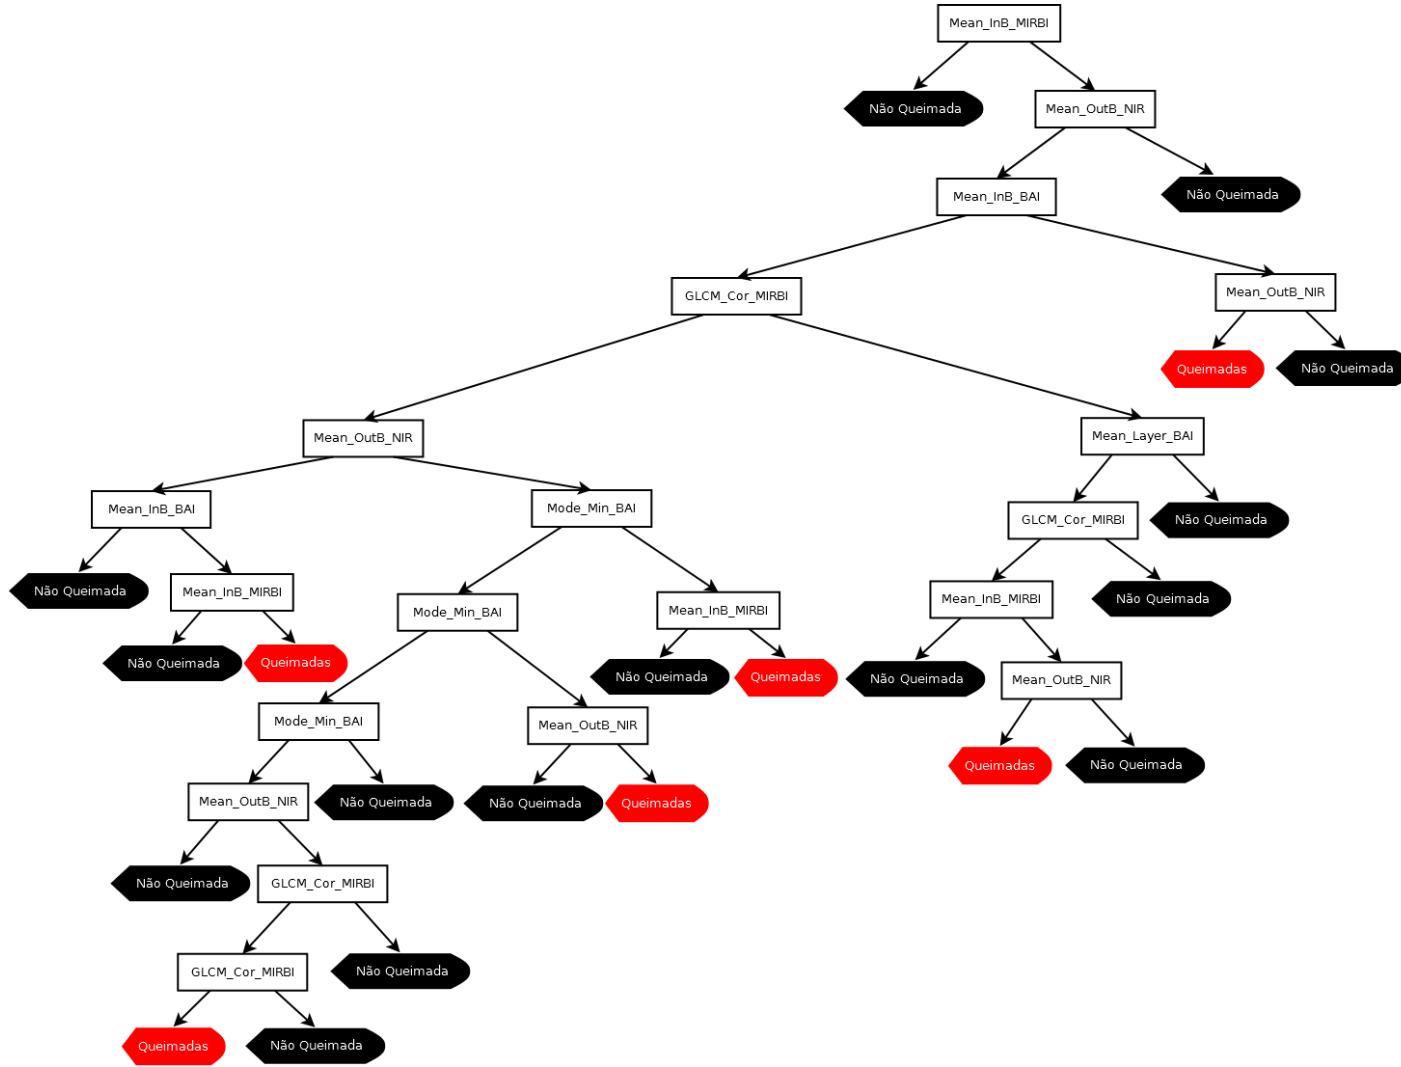


Figura C.3 - Árvore de decisão gerada pelo algoritmo J48 para AP2 – Landsat-8 OLI.

```
Mean_of_17 <= 2483
| GLCM_Hom_2 <= 0.231113
| | Mean_of__5 <= 2648.777778
| | | GLCM_Ang_4 <= 0.020116
| | | | Ratio_L_11 <= 0.133239
| | | | | modeMini_2 <= 0.003643
| | | | | | quantile51 <= 0.437555: Areas Nao Queimadas (12.0/1.0)
| | | | | | quantile51 > 0.437555: Areas Queimadas (42.0/17.0)
| | | | | modeMini_2 > 0.003643: Areas Queimadas (4.0)
| | | | Ratio_L_11 > 0.133239: Areas Nao Queimadas (113.0/7.0)
| | | GLCM_Ang_4 > 0.020116
| | | | GLCM_Ang_4 <= 0.155781
| | | | | Contrast_5 <= -185.657313
| | | | | | GLCM_Ent_2 <= 4.477014
| | | | | | | GLCM_Ent_2 <= 2.853194: Areas Nao Queimadas (12.0/6.0)
| | | | | | | GLCM_Ent_2 > 2.853194
| | | | | | | | Mean_of__5 <= 2551.538462: Areas Queimadas (77.0/2.0)
| | | | | | | | Mean_of__5 > 2551.538462
| | | | | | | | | Mean_Lay_5 <= 2230.75
| | | | | | | | | | Max_pixel1 <= 0.970876: Areas Nao Queimadas (4.0/2.0)
| | | | | | | | | | Max_pixel1 > 0.970876: Areas Queimadas (44.0/1.0)
| | | | | | | | | Mean_Lay_5 > 2230.75: Areas Queimadas (31.0/11.0)
| | | | | | | GLCM_Ent_2 > 4.477014: Areas Nao Queimadas (10.0/2.0)
| | | | | Contrast_5 > -185.657313
```

| | | | | Mean_of__5 <= 2605.583333

| | | | | | Mean_of_17 <= 2442.5

| | | | | | | Max_diff <= 1.643892: Areas Nao Queimadas (22.0/5.0)

| | | | | | | Max_diff > 1.643892: Areas Queimadas (203.0/81.0)

| | | | | | | Mean_of_17 > 2442.5: Areas Queimadas (28.0/1.0)

| | | | | | Mean_of__5 > 2605.583333: Areas Nao Queimadas (15.0/2.0)

| | | | GLCM_Ang_4 > 0.155781: Areas Nao Queimadas (25.0/1.0)

| | Mean_of__5 > 2648.777778: Areas Nao Queimadas (622.0/115.0)

| GLCM_Hom_2 > 0.231113

| | Mean_of__5 <= 2648.5

| | | GLCM_Hom_2 <= 0.676392

| | | | Skewness_2 <= 0.013357

| | | | | GLCM_Ang_4 <= 0.362562: Areas Nao Queimadas (60.0/17.0)

| | | | | GLCM_Ang_4 > 0.362562

| | | | | Contrast_5 <= -108.377981: Areas Queimadas (43.0/11.0)

| | | | | Contrast_5 > -108.377981: Areas Nao Queimadas (6.0/1.0)

| | | | Skewness_2 > 0.013357: Areas Queimadas (862.0/120.0)

| | | GLCM_Hom_2 > 0.676392: Areas Queimadas (407.0/12.0)

| | Mean_of__5 > 2648.5

| | | GLCM_Ent_2 <= 1.700521

| | | | GLCM_Hom_2 <= 0.492067: Areas Nao Queimadas (53.0/3.0)

| | | | GLCM_Hom_2 > 0.492067

| | | | | Contrast_5 <= -7223.904897: Areas Nao Queimadas (5.0)

| | | | | Contrast_5 > -7223.904897: Areas Queimadas (10.0)

| | | GLCM_Ent_2 > 1.700521

| | | | quantile51 <= 0.74731: Areas Nao Queimadas (9.0/2.0)

| | | | quantile51 > 0.74731: Areas Queimadas (141.0/26.0)

Mean_of_17 > 2483

| Mean_of__5 <= 2707.509434

| | GLCM_Ent_2 <= 4.706987

| | | Ratio_L_10 <= 0.183722

| | | | GLCM_Ang_4 <= 0.079688

| | | | | GLCM_Ent_2 <= 4.385913

| | | | | | Circular_2 <= 1.634297

| | | | | | | GLCM_Ent_2 <= 3.299673: Areas Nao Queimadas (15.0/6.0)

| | | | | | | GLCM_Ent_2 > 3.299673: Areas Queimadas (111.0/22.0)

| | | | | | | Circular_2 > 1.634297: Areas Nao Queimadas (16.0/4.0)

| | | | | | | GLCM_Ent_2 > 4.385913

| | | | | | | Max_pixel1 <= 0.971519: Areas Nao Queimadas (16.0/2.0)

| | | | | | | Max_pixel1 > 0.971519

| | | | | | | Max_pixel1 <= 0.997251: Areas Queimadas (3.0)

| | | | | | | Max_pixel1 > 0.997251

| | | | | | | | Mean_of_17 <= 2503.142857: Areas Nao Queimadas (7.0)

| | | | | | | | Mean_of_17 > 2503.142857

| | | | | | | | | modeMini_2 <= 0.003643: Areas Nao Queimadas (34.0/16.0)

| | | | | | | | | modeMini_2 > 0.003643: Areas Queimadas (2.0)

| | | | | GLCM_Ang_4 > 0.079688: Areas Nao Queimadas (14.0/1.0)

| | | Ratio_L_10 > 0.183722: Areas Nao Queimadas (29.0)

| | GLCM_Ent_2 > 4.706987

| | | quantile51 <= 0.890973: Areas Nao Queimadas (1674.0/19.0)

| | | quantile51 > 0.890973

| | | | Skewness_2 <= 1.039323

| | | | quantile51 <= 0.913124: Areas Nao Queimadas (7.0)

| | | | quantile51 > 0.913124

| | | | | Ratio_La_1 <= 0.888757: Areas Nao Queimadas (14.0/5.0)

| | | | | Ratio_La_1 > 0.888757: Areas Queimadas (5.0)

| | | | Skewness_2 > 1.039323: Areas Queimadas (6.0)

| Mean_of__5 > 2707.509434

| | quantile51 <= 0.932189

| | | Circular_2 <= 0.659675

| | | | Ratio_La_1 <= 0.19776: Areas Nao Queimadas (43909.0/3.0)

| | | | Ratio_La_1 > 0.19776

| | | | | GLCM_Ang_4 <= 0.014518: Areas Nao Queimadas (2001.0/10.0)

| | | | | GLCM_Ang_4 > 0.014518

| | | | | | Mean_of__5 <= 2937.888889

| | | | | | Ratio_L_10 <= 0.137884

| | | | | | | Mean_of__5 <= 2799.926829: Areas Queimadas (6.0)

| | | | | | | Mean_of__5 > 2799.926829: Areas Nao Queimadas (19.0/4.0)

| | | | | | | Ratio_L_10 > 0.137884: Areas Nao Queimadas (31.0)

| | | | | | | Mean_of__5 > 2937.888889: Areas Nao Queimadas (95.0)

| | | Circular_2 > 0.659675: Areas Nao Queimadas (1157.0/31.0)

| | quantile51 > 0.932189: Areas Nao Queimadas (113.0/11.0)

Figura C.3 – Continuação.

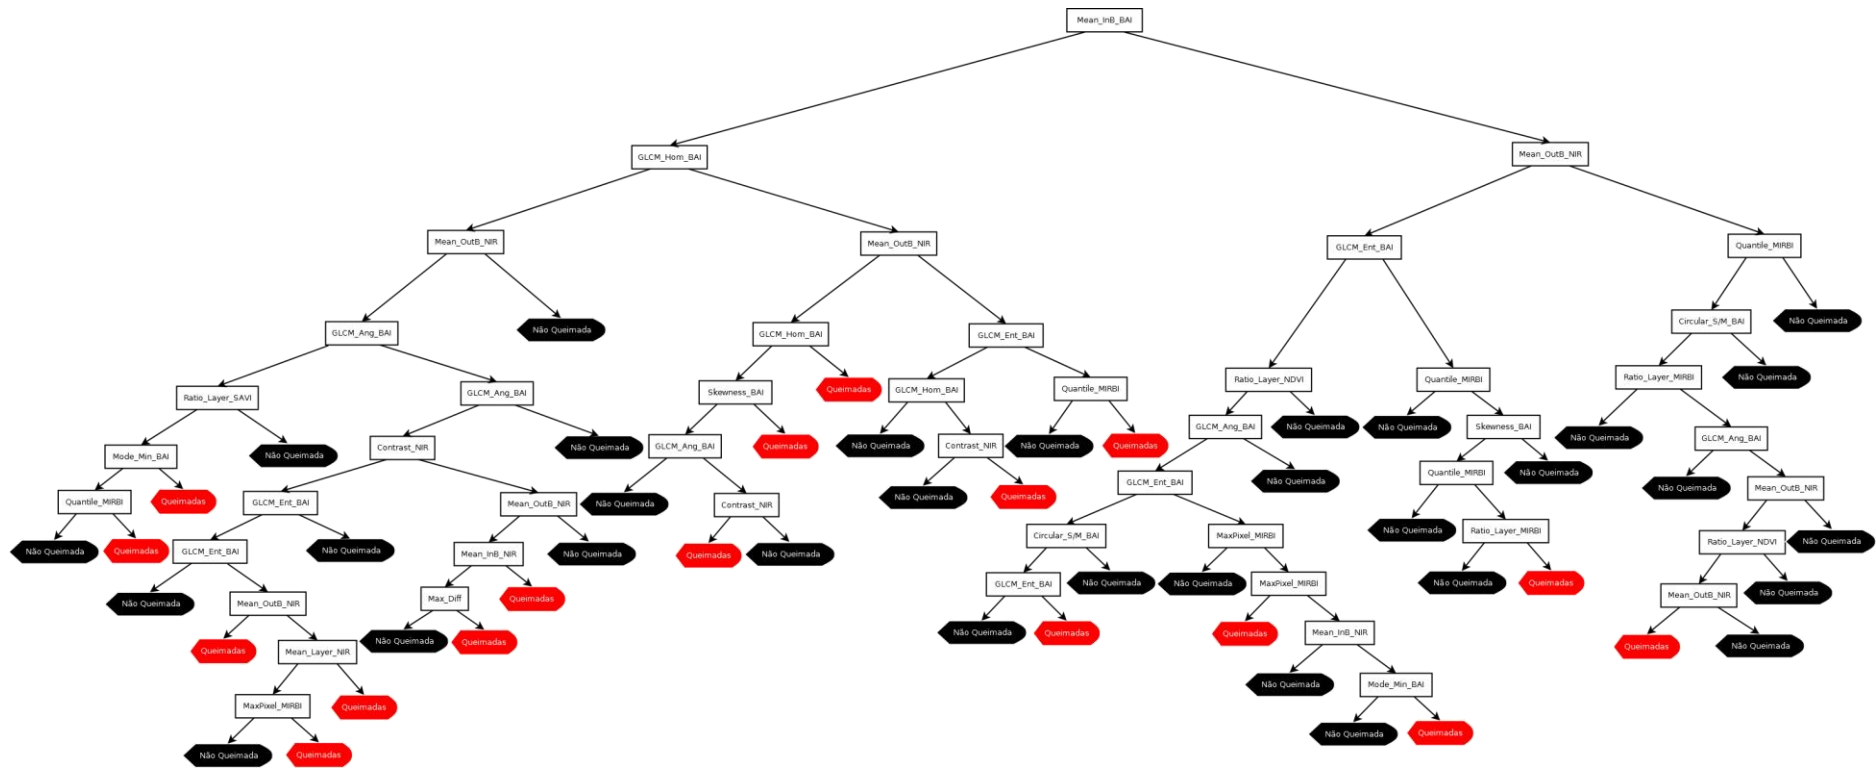


Figura C.4: Árvore de decisão gerada pelo algoritmo J48 para AP2 – Sentinel-2 MSI.

```
Mean_Lay_5 <= 2536.829787
| GLCM_Hom_2 <= 0.231199
| | GLCM_Hom_2 <= 0.108494: Areas Nao Queimadas (266.0/22.0)
| | GLCM_Hom_2 > 0.108494
| | | GLCM_Ang_4 <= 0.129477
| | | | GLCM_Ang_4 <= 0.043478: Areas Nao Queimadas (163.0/45.0)
| | | | GLCM_Ang_4 > 0.043478: Areas Queimadas (319.0/125.0)
| | | GLCM_Ang_4 > 0.129477: Areas Nao Queimadas (97.0/3.0)
| GLCM_Hom_2 > 0.231199
| | GLCM_Hom_2 <= 0.392926
| | | GLCM_Ang_4 <= 0.212552
| | | | Mean_Lay_5 <= 2004.352941: Areas Queimadas (198.0/11.0)
| | | | Mean_Lay_5 > 2004.352941
| | | | | Mean_Lay_5 <= 2347.36: Areas Queimadas (223.0/40.0)
| | | | | Mean_Lay_5 > 2347.36
| | | | | | Max_pixel1 <= 0.633596: Areas Nao Queimadas (7.0)
| | | | | | Max_pixel1 > 0.633596
| | | | | | | GLCM_Ang_4 <= 0.057338: Areas Nao Queimadas (7.0)
| | | | | | | GLCM_Ang_4 > 0.057338: Areas Queimadas (72.0/20.0)
| | | GLCM_Ang_4 > 0.212552
| | | | GLCM_Hom_2 <= 0.366792: Areas Nao Queimadas (79.0/8.0)
| | | | GLCM_Hom_2 > 0.366792: Areas Queimadas (18.0/6.0)
| | GLCM_Hom_2 > 0.392926
| | | GLCM_Hom_2 <= 0.515722: Areas Queimadas (328.0/36.0)
```


| | | GLCM_Hom_2 > 0.515722

| | | | GLCM_Hom_2 <= 0.972933: Areas Queimadas (671.0/20.0)

| | | | GLCM_Hom_2 > 0.972933

| | | | | Circular_1 <= -0.707107: Areas Nao Queimadas (7.0)

| | | | | Circular_1 > -0.707107: Areas Queimadas (18.0)

Mean_Lay_5 > 2536.829787: Areas Nao Queimadas (39106.0/149.0)

Número de Folhas: 16

Tamanho da árvore: 31

Figura C.4 - Continuação.

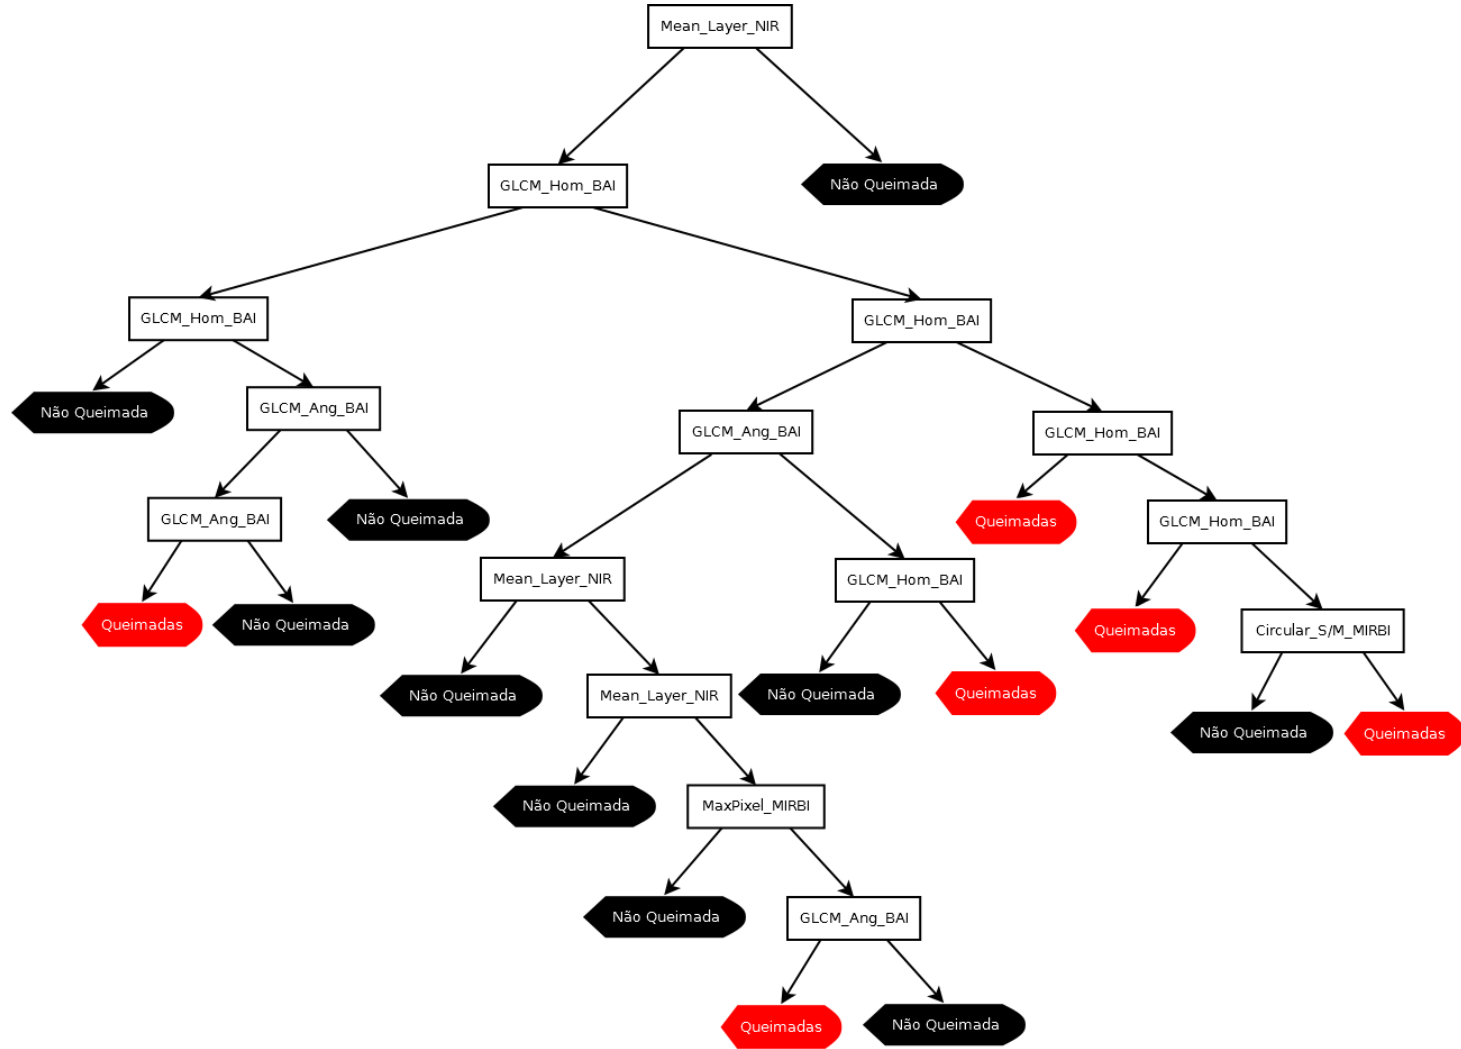


Figura C.5 - Árvore de decisão gerada pelo algoritmo J48 para AP3 – Landsat-8 OLI.

```
Circula_22 <= 2456.125
| Skewness_4 <= 0.785467
| | Skewness_8 <= -0.380916
| | | Mean_of__4 <= 0.385393
| | | | Mean_of__4 <= 0.258331
| | | | | Skewness_4 <= 0.31536
| | | | | | Contrast_5 <= -739.037799: Areas Nao Queimadas (17.0/1.0)
| | | | | | Contrast_5 > -739.037799
| | | | | | | Contrast_5 <= 33.651232: Areas Queimadas (162.0/71.0)
| | | | | | | Contrast_5 > 33.651232
| | | | | | | | Mean_of_13 <= 1948.942446: Areas Nao Queimadas (20.0)
| | | | | | | | Mean_of_13 > 1948.942446
| | | | | | | | | Circular_4 <= 0.94089: Areas Nao Queimadas (60.0/19.0)
| | | | | | | | | Circular_4 > 0.94089
| | | | | | | | | | Elliptic_F <= 0.486842: Areas Queimadas (7.0)
| | | | | | | | | | Elliptic_F > 0.486842: Areas Nao Queimadas (2.0/1.0)
| | | | | | | | | | Skewness_4 > 0.31536
| | | | | | | | | | | Skewness_8 <= -0.59647: Areas Queimadas (202.0/55.0)
| | | | | | | | | | | Skewness_8 > -0.59647
| | | | | | | | | | | | Mean_of__4 <= 0.237037
| | | | | | | | | | | | Skewness_4 <= 0.420312: Areas Queimadas (11.0/1.0)
| | | | | | | | | | | | Skewness_4 > 0.420312: Areas Nao Queimadas (52.0/23.0)
| | | | | | | | | | | | | Mean_of__4 > 0.237037: Areas Nao Queimadas (9.0)
| | | | | | | | | | | | | Mean_of__4 > 0.258331
```

| | | | Skewness_4 <= -0.100231: Areas Nao Queimadas (169.0/39.0)

| | | | Skewness_4 > -0.100231

| | | | | Mean_of_13 <= 2128.689655

| | | | | | modeMini_4 <= 0.160103

| | | | | | | Circular_4 <= 0.643372

| | | | | | | | Elliptic_F <= 0.916667

| | | | | | | | | Mean_of__4 <= 0.303682

| | | | | | | | | | Elliptic_F <= 0.191257: Areas Nao Queimadas (6.0/1.0)

| | | | | | | | | | Elliptic_F > 0.191257

| | | | | | | | | | | modeMini_4 <= 0.050514: Areas Queimadas (12.0)

| | | | | | | | | | | modeMini_4 > 0.050514

| | | | | | | | | | | | Mean_of__4 <= 0.289605: Areas Nao Queimadas (17.0/8.0)

| | | | | | | | | | | | Mean_of__4 > 0.289605: Areas Queimadas (7.0)

| | | | | | | | | | | | Mean_of__4 > 0.303682: Areas Nao Queimadas (51.0/17.0)

| | | | | | | | | | | | Elliptic_F > 0.916667: Areas Queimadas (7.0)

| | | | | | | | | | | | Circular_4 > 0.643372

| | | | | | | | | | | | Mean_of_13 <= 1957.538462

| | | | | | | | | | | | Elliptic_F <= 0.11828: Areas Queimadas (7.0/3.0)

| | | | | | | | | | | | Elliptic_F > 0.11828: Areas Nao Queimadas (38.0)

| | | | | | | | | | | | Mean_of_13 > 1957.538462

| | | | | | | | | | | | Skewness_4 <= 0.343229: Areas Nao Queimadas (16.0/1.0)

| | | | | | | | | | | | Skewness_4 > 0.343229

| | | | | | | | | | | | Mean_of__4 <= 0.309777: Areas Queimadas (12.0/1.0)

| | | | | | | | | | | | Mean_of__4 > 0.309777

| | | | | | | | | | | | Skewness_8 <= -0.766914

| | | | | | | | | | | | Contrast_5 <= -241.157266: Areas Queimadas (3.0)

| | | | | | | | | | Contrast_5 > -241.157266: Areas Nao Queimadas (2.0/1.0)

| | | | | | | | | | Skewness_8 > -0.766914: Areas Nao Queimadas (10.0)

| | | | | | | modeMini_4 > 0.160103: Areas Nao Queimadas (76.0/10.0)

| | | | | | Mean_of_13 > 2128.689655: Areas Nao Queimadas (258.0/129.0)

| | | Mean_of__4 > 0.385393

| | | | Elliptic_F <= 0.08

| | | | | Circular_4 <= 0.583678: Areas Nao Queimadas (47.0/12.0)

| | | | | Circular_4 > 0.583678: Areas Queimadas (58.0/25.0)

| | | | Elliptic_F > 0.08: Areas Nao Queimadas (555.0/68.0)

| | Skewness_8 > -0.380916

| | | Circular_4 <= 0.665024: Areas Nao Queimadas (2022.0/286.0)

| | | Circular_4 > 0.665024

| | | | Mean_of_13 <= 1060.941176

| | | | | Elliptic_F <= 0.859719: Areas Nao Queimadas (16.0/8.0)

| | | | | Elliptic_F > 0.859719: Areas Queimadas (13.0)

| | | | Mean_of_13 > 1060.941176: Areas Nao Queimadas (1304.0/358.0)

| Skewness_4 > 0.785467

| | Mean_of__4 <= 0.392209

| | | Skewness_8 <= -0.590562: Areas Queimadas (1229.0/323.0)

| | | Skewness_8 > -0.590562

| | | | Contrast_5 <= -51.315945

| | | | | Mean_of__4 <= 0.185743: Areas Queimadas (401.0/135.0)

| | | | | Mean_of__4 > 0.185743

| | | | | Elliptic_F <= 0.491961: Areas Nao Queimadas (233.0/70.0)

| | | | | Elliptic_F > 0.491961

| | | | | | Mean_of__4 <= 0.365846

| | | | | | | Skewness_8 <= 0.349577

| | | | | | | modeMini_4 <= 0.095034: Areas Queimadas (159.0/54.0)

| | | | | | | modeMini_4 > 0.095034: Areas Nao Queimadas (37.0/15.0)

| | | | | | | Skewness_8 > 0.349577: Areas Nao Queimadas (108.0/40.0)

| | | | | | | Mean_of__4 > 0.365846: Areas Nao Queimadas (30.0/4.0)

| | | | Contrast_5 > -51.315945

| | | | | Circular_4 <= 0.763135: Areas Nao Queimadas (95.0/14.0)

| | | | | Circular_4 > 0.763135

| | | | | | Mean_of__4 <= 0.216835: Areas Nao Queimadas (55.0/13.0)

| | | | | | Mean_of__4 > 0.216835: Areas Queimadas (19.0/4.0)

| | Mean_of__4 > 0.392209

| | | Mean_of_13 <= 1838.192308: Areas Nao Queimadas (76.0/3.0)

| | | Mean_of_13 > 1838.192308

| | | | modeMini_4 <= 0.323202

| | | | | Skewness_4 <= 1.476345

| | | | | | Mean_of__4 <= 0.469596: Areas Nao Queimadas (165.0/61.0)

| | | | | | Mean_of__4 > 0.469596

| | | | | | Skewness_8 <= -1.025766

| | | | | | | Elliptic_F <= 0.850932: Areas Nao Queimadas (30.0/7.0)

| | | | | | | Elliptic_F > 0.850932: Areas Queimadas (4.0)

| | | | | | | Skewness_8 > -1.025766: Areas Nao Queimadas (90.0/7.0)

| | | | | Skewness_4 > 1.476345

| | | | | | Mean_of__4 <= 0.564587

| | | | | | | Circular_4 <= 0.529865: Areas Nao Queimadas (29.0/12.0)

| | | | | | | Circular_4 > 0.529865: Areas Queimadas (32.0/3.0)

| | | | | | | Mean_of__4 > 0.564587: Areas Nao Queimadas (7.0)

| | | | modeMini_4 > 0.323202: Areas Nao Queimadas (112.0/8.0)

Circula_22 > 2456.125

| Mean_of_13 <= 2626.971429

| | Elliptic_F <= 0.832447: Areas Nao Queimadas (3341.0/187.0)

| | Elliptic_F > 0.832447

| | | Mean_of__4 <= 0.488059

| | | | Mean_of__4 <= 0.372569

| | | | | Circular_4 <= 0.713287

| | | | | | Circular_4 <= 0.227222: Areas Nao Queimadas (13.0/5.0)

| | | | | | Circular_4 > 0.227222

| | | | | | Elliptic_F <= 0.944444

| | | | | | | Contrast_5 <= -329.709028: Areas Queimadas (2.0)

| | | | | | | Contrast_5 > -329.709028: Areas Nao Queimadas (2.0/1.0)

| | | | | | | Elliptic_F > 0.944444: Areas Queimadas (27.0)

| | | | | | | Circular_4 > 0.713287: Areas Nao Queimadas (6.0)

| | | | | Mean_of__4 > 0.372569

| | | | | | Mean_of_13 <= 1855.239316: Areas Nao Queimadas (27.0)

| | | | | | Mean_of_13 > 1855.239316

| | | | | | | Skewness_4 <= 0.667282

| | | | | | | | Skewness_8 <= 0.574006

| | | | | | | | | Circula_22 <= 2582.0625: Areas Nao Queimadas (32.0/7.0)

| | | | | | | | | Circula_22 > 2582.0625

| | | | | | | | | Elliptic_F <= 0.861635: Areas Nao Queimadas (3.0)

| | | | | | | | | Elliptic_F > 0.861635: Areas Queimadas (21.0/7.0)

| | | | | | | | | Skewness_8 > 0.574006: Areas Nao Queimadas (15.0)

| | | | | | | | | Skewness_4 > 0.667282

| | | | | | Circula_22 <= 2514.125: Areas Nao Queimadas (5.0)

| | | | | | Circula_22 > 2514.125

| | | | | | Circular_4 <= 0.668603: Areas Queimadas (23.0/1.0)

| | | | | | Circular_4 > 0.668603: Areas Nao Queimadas (2.0)

| | | Mean_of__4 > 0.488059

| | | | Skewness_8 <= -0.482954

| | | | Skewness_4 <= -0.248426: Areas Nao Queimadas (18.0)

| | | | Skewness_4 > -0.248426

| | | | | | Circula_22 <= 2836.3125: Areas Nao Queimadas (29.0/4.0)

| | | | | | Circula_22 > 2836.3125

| | | | | | Mean_of_13 <= 2156.921569: Areas Nao Queimadas (3.0)

| | | | | | Mean_of_13 > 2156.921569: Areas Queimadas (10.0/1.0)

| | | | Skewness_8 > -0.482954: Areas Nao Queimadas (125.0/4.0)

| Mean_of_13 > 2626.971429: Areas Nao Queimadas (29386.0/164.0)

Numero de Folhas: 72

Tamanho da árvore: 143

Figura C.6 - Árvore de decisão gerada pelo algoritmo J48 para AP3 – CBERS-4 MUX.

```
Mean_Lay_5 <= 45.4878
| Contrast_5 <= 11.54822
| | Mean_of__4 <= 0.520891
| | | Skewness_4 <= 0.834023
| | | | Ratio_La_7 <= 0.299213
| | | | | Ratio_La_8 <= 0.292338
| | | | | | Circular_4 <= 0.225094: Areas Nao Queimadas (36.0/1.0)
| | | | | | Circular_4 > 0.225094
| | | | | | | modeMini_4 <= 0.096799
| | | | | | | | Circular_4 <= 0.533765: Areas Queimadas (11.0/1.0)
| | | | | | | | Circular_4 > 0.533765: Areas Nao Queimadas (14.0/2.0)
| | | | | | | | modeMini_4 > 0.096799: Areas Nao Queimadas (72.0/16.0)
| | | | | | | | Ratio_La_8 > 0.292338
| | | | | | | | Main_direc <= 1.013961
| | | | | | | | Ratio_La_8 <= 0.29911
| | | | | | | | Contrast_5 <= -64.19995: Areas Queimadas (6.0)
| | | | | | | | Contrast_5 > -64.19995: Areas Nao Queimadas (4.0/2.0)
| | | | | | | | Ratio_La_8 > 0.29911
| | | | | | | | Contrast_5 <= -84.607117
| | | | | | | | | Mean_of__4 <= 0.216248: Areas Nao Queimadas (10.0/1.0)
| | | | | | | | | Mean_of__4 > 0.216248: Areas Queimadas (7.0)
| | | | | | | | | Contrast_5 > -84.607117: Areas Nao Queimadas (65.0/4.0)
| | | | | | | | Main_direc > 1.013961
```

| | | | | | Contrast_5 <= -137.681317
 | | | | | | Mean_of__4 <= 0.448838
 | | | | | | Circular_4 <= 0.629927
 | | | | | | Ratio_La_8 <= 0.310956
 | | | | | | Main_direc <= 16.86125: Areas Queimadas (14.0/5.0)
 | | | | | | Main_direc > 16.86125
 | | | | | | modeMini_4 <= 0.096799: Areas Queimadas (96.0)
 | | | | | | modeMini_4 > 0.096799
 | | | | | | Ratio_La_7 <= 0.257008: Areas Queimadas (53.0)
 | | | | | | Ratio_La_7 > 0.257008
 | | | | | | Ratio_La_8 <= 0.297505: Areas Nao Queimadas (2.0)
 | | | | | | Ratio_La_8 > 0.297505: Areas Queimadas (13.0/1.0)
 | | | | | | Ratio_La_8 > 0.310956: Areas Queimadas (36.0/10.0)
 | | | | | | Circular_4 > 0.629927: Areas Queimadas (71.0/21.0)
 | | | | | | Mean_of__4 > 0.448838: Areas Nao Queimadas (75.0/34.0)
 | | | | | | Contrast_5 > -137.681317
 | | | | | | Mean_of__4 <= 0.36097
 | | | | | | Contrast_5 <= -39.48121
 | | | | | | Circular_4 <= 0.538788: Areas Queimadas (208.0/36.0)
 | | | | | | Circular_4 > 0.538788
 | | | | | | Mean_of__4 <= 0.300549: Areas Queimadas (69.0/21.0)
 | | | | | | Mean_of__4 > 0.300549: Areas Nao Queimadas (44.0/15.0)
 | | | | | | Contrast_5 > -39.48121
 | | | | | | Skewness_4 <= 0.001796: Areas Nao Queimadas (71.0/18.0)
 | | | | | | Skewness_4 > 0.001796: Areas Queimadas (135.0/60.0)

| | | | | | | | Mean_of__4 > 0.36097

| | | | | | | | Circular_4 <= 0.298697

| | | | | | | | modeMini_4 <= 0.322603

| | | | | | | | Main_direc <= 139.9321

| | | | | | | | modeMini_4 <= 0.258088

| | | | | | | | modeMini_4 <= 0.193567: Areas Queimadas (12.0/4.0)

| | | | | | | | modeMini_4 > 0.193567: Areas Nao Queimadas (8.0/1.0)

| | | | | | | | modeMini_4 > 0.258088

| | | | | | | | modeMini_4 <= 0.29034: Areas Queimadas (7.0)

| | | | | | | | modeMini_4 > 0.29034

| | | | | | | | Ratio_La_7 <= 0.25353: Areas Nao Queimadas (2.0)

| | | | | | | | Ratio_La_7 > 0.25353: Areas Queimadas (3.0)

| | | | | | | | Main_direc > 139.9321: Areas Queimadas (10.0)

| | | | | | | | modeMini_4 > 0.322603: Areas Nao Queimadas (17.0/5.0)

| | | | | | | | Circular_4 > 0.298697: Areas Nao Queimadas (308.0/98.0)

| | | | Ratio_La_7 > 0.299213: Areas Nao Queimadas (57.0)

| | | Skewness_4 > 0.834023

| | | | Ratio_La_8 <= 0.295089

| | | | | modeMini_4 <= 0.29034

| | | | | Ratio_La_8 <= 0.288672: Areas Nao Queimadas (5.0)

| | | | | Ratio_La_8 > 0.288672: Areas Queimadas (58.0/22.0)

| | | | | modeMini_4 > 0.29034: Areas Nao Queimadas (14.0)

| | | | Ratio_La_8 > 0.295089: Areas Queimadas (1969.0/224.0)

| | Mean_of__4 > 0.520891

| | | Mean_of__4 <= 0.587735

| | | Skewness_4 <= 0.112365: Areas Nao Queimadas (28.0)

| | | Skewness_4 > 0.112365

| | | | Ratio_La_7 <= 0.266262

| | | | | Skewness_4 <= 2.159594: Areas Nao Queimadas (128.0/45.0)

| | | | | Skewness_4 > 2.159594: Areas Queimadas (9.0)

| | | | | Ratio_La_7 > 0.266262: Areas Nao Queimadas (28.0/1.0)

| | | Mean_of__4 > 0.587735: Areas Nao Queimadas (342.0/6.0)

| Contrast_5 > 11.54822

| | Skewness_4 <= 0.461604: Areas Nao Queimadas (955.0/71.0)

| | Skewness_4 > 0.461604

| | | modeMini_4 <= 0.00002

| | | | Skewness_4 <= 0.605994: Areas Nao Queimadas (10.0/1.0)

| | | | Skewness_4 > 0.605994: Areas Queimadas (42.0/11.0)

| | | modeMini_4 > 0.00002

| | | | Contrast_5 <= 27.37924

| | | | | modeMini_4 <= 0.064513: Areas Nao Queimadas (6.0)

| | | | | modeMini_4 > 0.064513

| | | | | | Circular_4 <= 0.281769: Areas Nao Queimadas (8.0/2.0)

| | | | | | Circular_4 > 0.281769: Areas Queimadas (22.0/3.0)

| | | | Contrast_5 > 27.37924: Areas Nao Queimadas (170.0/28.0)

Mean_Lay_5 > 45.4878

| Circular_4 <= 0.265942

| | Circular_4 <= -0.774597

| | | modeMini_4 <= -33999999521400000000000000000000: Areas Queimadas (21.0/1.0)

| | | modeMini_4 > -33999999521400000000000000000000: Areas Nao Queimadas (14.0)

| | Circular_4 > -0.774597
| | | Ratio_La_8 <= 0.305676
| | | | Ratio_La_7 <= 0.248658: Areas Nao Queimadas (13513.0/2.0)
| | | | Ratio_La_7 > 0.248658
| | | | | modeMini_4 <= 0.387119
| | | | | Ratio_La_7 <= 0.25538: Areas Nao Queimadas (102.0/2.0)
| | | | | Ratio_La_7 > 0.25538
| | | | | | Contrast_5 <= 22.68519: Areas Queimadas (4.0)
| | | | | | Contrast_5 > 22.68519: Areas Nao Queimadas (2.0)
| | | | | modeMini_4 > 0.387119: Areas Nao Queimadas (419.0/2.0)
| | | Ratio_La_8 > 0.305676
| | | | Contrast_5 <= 60.13625
| | | | | Skewness_4 <= 0.806907: Areas Nao Queimadas (30.0/15.0)
| | | | | Skewness_4 > 0.806907: Areas Queimadas (9.0)
| | | | Contrast_5 > 60.13625: Areas Nao Queimadas (11.0)
| Circular_4 > 0.265942: Areas Nao Queimadas (1837.0/209.0)

APÊNDICE D - MATRIZES DE CONFUSÃO DAS ÁRVORES DE DECISÃO GERADAS PELO ALGORITMO J48

Figura D.1 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP1: (A) Landsat-8 OLI; (B) Sentinel-2 MSI.

AP1		OLI Landsat-8			
		Instâncias (n° segmentos)		Total (n°)	Acurácia do Usuário (%)
		Áreas Queimadas	Áreas Não Queimadas		
J48	Áreas Queimadas	2019	301	2320	87,03
	Áreas Não Queimadas	320	64945	65265	99,51
Total (n°)		2339	65246	67585	
Acurácia do Produtor (%)		86,32	99,54	Exatidão Global	99,08
Erros de Omissão (Eo)		0,14		Coefficiente Dice (DC)	0,87
Erros de Comissão (Ec)		0,13		Erro Relativo (RelB)	300,86

(A)

AP1		MSI Sentinel-2			
		Instâncias (n° segmentos)		Total (n°)	Acurácia do Usuário (%)
		Áreas Queimadas	Áreas Não Queimadas		
J48	Áreas Queimadas	1591	419	2010	79,15
	Áreas Não Queimadas	361	66235	66596	99,46
Total (n°)		1952	66654	68606	
Acurácia do Produtor (%)		81,51	99,37	Exatidão Global	98,86
Erros de Omissão (Eo)		0,18		Coefficiente Dice (DC)	0,80
Erros de Comissão (Ec)		0,21		Erro Relativo (RelB)	418,82

(B)

Figura D.2 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP2: (A) Landsat-8 OLI; (B) Sentinel-2 MSI.

AP2		OLI Landsat-8			
		Instâncias (n° segmentos)		Total (n°)	Acurácia do Usuário (%)
		Áreas Queimadas	Áreas Não Queimadas		
J48	Áreas Queimadas	2563	493	3056	83,87
	Áreas Não Queimadas	432	74727	75159	99,43
Total (n°)		2995	75220	78215	
Acurácia do Produtor (%)		85,58	99,34	Exatidão Global	98,82
Erros de Omissão (Eo)		0,14		Coefficiente Dice (DC)	0,85
Erros de Comissão (Ec)		0,16		Erro Relativo (RelB)	492,86

(A)

AP2		MSI Sentinel-2			
		Instâncias (n° segmentos)		Total (n°)	Acurácia do Usuário (%)
		Áreas Queimadas	Áreas Não Queimadas		
J48	Áreas Queimadas	2364	398	2762	85,59
	Áreas Não Queimadas	360	59246	59606	99,40
Total (n°)		2724	59644	62368	
Acurácia do Produtor (%)		86,78	99,33	Exatidão Global	98,78
Erros de Omissão (Eo)		0,13		Coefficiente Dice (DC)	0,86
Erros de Comissão (Ec)		0,14		Erro Relativo (RelB)	397,87

(B)

Figura D.3 - Resultado da matriz de confusão da árvore de decisão gerada pelo algoritmo J48 para AP3: (A) Landsat-8 OLI; (B) CBERS-4 MUX.

AP3		OLI Landsat-8			
		Instâncias (n° segmentos)		Total (n°)	Acurácia do Usuário (%)
		Áreas Queimadas	Áreas Não Queimadas		
J48	Áreas Queimadas	2573	2455	5028	51,17
	Áreas Não Queimadas	1080	55765	56845	98,10
Total (n°)		3653	58220	61873	
Acurácia do Produtor (%)		70,44	95,78	Exatidão Global	94,29
Erros de Omissão (Eo)		0,30		Coefficiente Dice (DC)	0,59
Erros de Comissão (Ec)		0,49		Erro Relativo (RelB)	2454,70

(A)

AP3		Landsat-8 OLI			
		Reference Map (Km ²)		Total (Km ²)	User Accuracy (%)
		Burned Area	Unburned Area		
J48	Burned Area	2573,00	2455,00	5028,00	51,17
	Unburned Area	1080,00	55765,00	56845,00	98,10
Total (Km ²)		3653,00	58220,00	61873,00	
Producer Accuracy (%)		70,44	95,78	Global Accuracy	94,29
Omission Error		0,30		Dice Coefficient	0,59
Commission Error		0,49		Relative Bias	2454,70

(B)