



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E TECNOLOGIAS  
DA GEOINFORMAÇÃO

TARLEI APARECIDO SANTOS

**INTEGRAÇÃO DE IMAGENS MULTIFONTES APLICADA AO MAPEAMENTO  
DE CONTORNOS DE FITOFISIONOMIAS PRESENTES NA ZONA DE  
AMORTECIMENTO DA REBIO SERRA NEGRA**

RECIFE

2021

TARLEI APARECIDO SANTOS

**INTEGRAÇÃO DE IMAGENS MULTIFONTES APLICADA AO MAPEAMENTO  
DE CONTORNOS DE FITOFISIONOMIAS PRESENTES NA ZONA DE  
AMORTECIMENTO DA REBIO SERRA NEGRA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, do Centro de Tecnologia e Geociências, como parte dos requisitos para obtenção do grau de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

**Área de concentração:** Ciências Geodésicas e Tecnologias da Geoinformação.

Orientador: Prof. Dr. João Rodrigues Tavares Júnior.

RECIFE

2021

Catálogo na fonte  
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

- S237i Santos, Tarlei Aparecido.  
Integração de imagens multifontes aplicada ao mapeamento de contornos de fitofisionomias presentes na zona de amortecimento da Rebio Serra Negra / Tarlei Aparecido Santos. - 2021.  
168 folhas, il.; tab. e abr.
- Orientador: Prof. Dr. João Rodrigues Tavares Júnior.
- Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, 2021.  
Inclui Referências.
1. Engenharia Cartográfica. 2. Mineração de dados. 3. Multiespectral.  
4. Multirresolução. 5. Varredura a laser. I. Tavares Júnior, João Rodrigues (Orientador). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2022-53

TARLEI APARECIDO SANTOS

**INTEGRAÇÃO DE IMAGENS MULTIFONTES APLICADA AO MAPEAMENTO  
DE CONTORNOS DE FITOFISIONOMIAS PRESENTES NA ZONA DE  
AMORTECIMENTO DA REBIO SERRA NEGRA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, do Centro de Tecnologia e Geociências, como parte dos requisitos para obtenção do grau de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação. **Área de concentração:** Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: 30 / 08 / 2021.

**BANCA EXAMINADORA**

---

Prof. Dr. João Rodrigues Tavares Júnior (Orientador)  
Universidade Federal de Pernambuco

---

Prof. Dr<sup>a</sup>. Ana Lúcia Bezerra Candeias (Examinadora Interna)  
Universidade Federal de Pernambuco

---

Prof. Dr<sup>a</sup>. Cristiana Coutinho Duarte (Examinadora Externa)  
Universidade Federal de Pernambuco

Dedico as minhas duas mães, Cecília Maria de Jesus e Nezia Maria de Jesus, aos meus irmãos e demais familiares, e aos meus colegas e amigos que diretamente ou indiretamente contribuíram para minha formação.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado força e sabedoria, e por ter me guiado sempre;

Agradeço as minhas duas mães, Cecília Maria de Jesus e Nezia Maria de Jesus, por sempre estarem ao meu lado, por todo amor e carinho dado, e pela torcida que sempre tive;

Agradeço aos meus tios Celson Linos dos Santos, e Vânia Maria Lourenço por todo apoio dado;

Agradeço aos meus irmãos Edimar Francisco dos Santos, e Cirlei Maria de Jesus pelo apoio e ajuda concedida, e aos demais familiares e amigos;

Agradeço aos meus colegas de curso pelos bons momentos que vivenciamos juntos, por todos os laços criados e pelas alegrias que compartilhamos;

Agradeço ao Professor João Rodrigues Tavares Júnior por todas as oportunidades e ensinamentos oferecidos ao longo do curso;

Um agradecimento em especial à Marcos Vinícius, Luiza Rodrigues, Mônica Taires, Gesiane Simara e Jaciele Oliveira pela cooperação no desenvolvimento da dissertação;

Um agradecimento também especial ao professor Marcelo Rossi e as professoras Thais Ribeiro e Carla Madureira pelo apoio e colaboração;

Agradeço ao Laboratório ESPAÇO de Sensoriamento Remoto e Estudos Ambientais, do Departamento de Geografia da UFRJ, pela cooperação e disponibilização da licença do *software* eCognition Developer;

Agradeço aos diversos docentes que contribuíram para minha formação ao longo dessa jornada, que me ensinaram, inspiraram e promoveram troca de conhecimentos;

Agradeço a coordenação do Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, por toda orientação e o apoio ao longo desses anos;

Agradeço a todos os servidores da UFPE pela honra de ter estudado aqui.

No mais, muitíssimo obrigado a todos!

“A persistência é o caminho do êxito” (CHAPLIN, p. 118,1997).

## RESUMO

A REBIO de Serra Negra foi criada com objetivo de proteger uns dos últimos remanescentes de Mata de Formação Orográfica (Mata Atlântica em meio à Caatinga), também conhecida como brejo de altitude, presente no bioma da Caatinga. Localizada entre os municípios de Inajá, Floresta e Tacaratu no estado de Pernambuco, a Reserva possui um valor singular para a conservação da biodiversidade da região. Composta por espécies de ocorrência nos biomas de Mata Atlântica, Cerrado e Caatinga, é considerada uma área especial, devido à sua formação geoambiental e características fisiográficas. Com intuito de compreender melhor a composição da vegetação da REBIO, o objetivo desta pesquisa foi realizar a integração de imagens de multifontes para o mapeamento de diferentes fitofisionomias de vegetação e áreas antrópicas, presentes na Zona de Amortecimento proposta no plano de manejo da REBIO de Serra Negra, empregando-se o método de segmentação multirresolução e mineração de dados. As fitofisionomias definidas para classes de legenda foram: Floresta de Altitude (FA); Caatinga Arbustiva Densa (CAD); Caatinga Seca e Esparsa (CSE); e Área de Transição (AT); além de áreas de Massas D'Água (MAG) e Solo Exposto (SEXP), identificadas com base em fotointerpretação das imagens, e as descrições dadas no plano de manejo da UC. Foram utilizados dados de varredura a laser disponibilizados pelo Programa (PE3d) e imagens multiespectrais do satélite CBERS – 4, disponibilizadas pelo INPE, referentes ao dia 23/01/2017 (final do período seco) e do dia 20/08/2019 (final do período chuvoso). Todas as imagens passaram pela etapa de pré-processamento com objetivo de refinar os planos de informação. Com objetivo de testar diferentes combinações entre as imagens multiespectrais, índices espectrais e os dados de varredura a laser, foram criados oito planos de informações (camadas de entrada), para cada ano base, a fim de testar suas influencias no mapeamento. Para classificação das diferentes fitofisionomias e áreas antropizadas presentes na REBIO, os planos de informações passaram pelas etapas de segmentação multirresolução orientada ao objeto, seleção dos atributos texturais e estatísticos e classificação pelo método de mineração de dados (Rede Neurais Artificiais). Ao final da classificação os resultados foram avaliados com base em amostras de referências e por meio de indicadores de concordância e exatidão. Entre os resultados obtidos, todos os planos de informações apresentaram resultados satisfatórios. Os indicadores de concordância Kappa variaram entre 0,81 a 0,86, enquanto que os valores de exatidão global foram superiores a 80%. As Áreas de AT foram melhores delimitadas para as imagens provenientes do ano base 2019, em contrapartida áreas de FA foram melhores identificadas para imagens do ano base 2017. As áreas de CAD, CSE e SEXP foram bem

delimitadas em ambos os anos analisados, e a ausência de amostragem para classe de MAG obtiveram os piores resultados. As conclusões finais mostraram que com base nos indicadores de concordância e exatidão não foi possível identificar qual plano de informação obteve o melhor desempenho e resultado. Todos os resultados obtidos foram satisfatórios e atingiram aos objetivos propostos.

**Palavras-chave:** mineração de dados; multiespectral; multirresolução; varredura a laser.

## ABSTRACT

The Serra Negra REBIO was created with the objective of protecting one of the last remnants of the Orographic Formation Forest (Atlantic Forest in the middle of the Caatinga), also known as high altitude swamp, present in the Caatinga biome. Located between the municipalities of Inajá, Floresta and Tacaratu in the state of Pernambuco, the Reserve has a unique value for the conservation of biodiversity in the region. Made up of species that occur in the Atlantic Forest, Cerrado and Caatinga biomes, it is considered a special area due to its geo-environmental formation and physiographic characteristics. In order to better understand the composition of the vegetation of the REBIO, the objective of this research was to perform the integration of multisource images for the mapping of different vegetation physiognomies and anthropic areas, present in the Buffer Zone proposed in the management plan of the Serra Negra REBIO, using the method of multiresolution segmentation and data mining. The phytophysionomies defined for caption classes were: Altitude Forest (AF); Dense Shrubby Caatinga (CAD); Dry and Sparse Caatinga (CSE); and Transition Area (AT); as well as areas of Water Mass (WMA) and Exposed Soil (SEXP), identified based on photointerpretation of the images, and the descriptions given in the UC management plan. Laser scanning data made available by the Program (PE3d) and multispectral images from the CBERS - 4 satellite, made available by INPE, referring to 01/23/2017 (end of the dry season) and 08/20/2019 (end of the rainy season) were used. All images were pre-processed in order to refine the information planes. In order to test different combinations between the multispectral images, spectral indices and the laser scan data, eight information planes (input layers) were created for each base year, in order to test their influence on the mapping. To classify the different phytophysionomies and anthropized areas present in the REBIO, the information layers went through the stages of object-oriented multiresolution segmentation, selection of textural and statistical attributes, and classification by the data mining method (Artificial Neural Networks). At the end of the classification the results were evaluated based on reference samples and through agreement and accuracy indicators. Among the results obtained, all information plans presented satisfactory results. Kappa agreement indicators ranged from 0.81 to 0.86, while overall accuracy values were higher than 80%. TA areas were better delineated for images coming from the base year 2019, in contrast FA areas were better identified for images from the base year 2017. Areas of CAD, CSE and SEXP were well delineated in both years analyzed, and the absence of sampling for MAG class obtained the worst results. The final conclusions showed that based on the

indicators of agreement and accuracy it was not possible to identify which information plan obtained the best performance and result. All the results obtained were satisfactory and met the proposed objectives.

**Keywords:** data mining; multispectral; multiresolution; laser scan.

## LISTA DE FIGURAS

Figura 1 - Partes componentes de um sistema sensor. ....	27
Figura 2 - Assinatura espectral de diferentes alvos. ....	33
Figura 3 - Processo de mineração de dados de imagens.....	46
Figura 4 - Modelo de um neurônio artificial. ....	48
Figura 5 - Função Limiar. ....	49
Figura 6 - Função Sigmoidal. ....	49
Figura 7 - Função tangente hiperbólica. ....	50
Figura 8 - Representação gráfica de uma Rede Neural Artificial.....	51
Figura 9 - Mapa de localização da área de estudo. ....	61
Figura 10 - Fluxograma da etapa do pré-processamento das imagens multiespectrais e pancromática. ....	67
Figura 11 - Fluxograma da etapa do pré-processamento do MDT e MDE. ....	68
Figura 12 - Fluxograma da etapa final segmentação e classificação dos dados. ....	69
Figura 13 - Pontos de controle utilizado para o registro das imagens multiespectrais e pancromáticas. ....	71
Figura 14 - Janela do software eCognition Developer 9.2 para configuração dos critérios da homogeneidade. ....	78
Figura 15 - Exemplo de arquivo Microsoft Excel de extensão (XLSX), com seus respectivos atributos. ....	89
Figura 16 - Exemplo de arquivo de Valores Separados por Vírgula (CSV). ....	90
Figura 17 - Exemplo de arquivo ARFF. ....	91
Figura 18 - Exemplo de Rede Neural Artificial gerada no WEKA. ....	94
Figura 19 - Arquivo de saída WEKA 3.8. ....	95
Figura 20 - Exemplo de classes (ilhas) isoladas. ....	105
Figura 21 - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: I-II). ....	106
Figura 22 - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: III-IV). ....	107
Figura 23 - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: V-VI). ....	108
Figura 24 - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: VII-VIII). ....	109
Figura 25 - Áreas de sobreposições e conflitos. ....	114
Figura 26 - Comparação dos índices espectrais do NDVI, SAVI e IAF, para os anos 2017 e 2019. ....	136
Figura 27 - Modelo Digital de Altura (MDA). ....	144

## LISTA DE GRÁFICOS

Gráfico 1	- Histórico da precipitação total mensal (em mm), referente ao período de 01 de janeiro de 2016 a 31 de janeiro de 2019, das estações convencionais de Água Branca (AL), Arcoverde (PE), Cabrobó (PE) e Pão de Açúcar (AL). .....	65
Gráfico 2	- Histórico da precipitação total mensal (em mm), referente ao período de 01 de janeiro de 2016 a 31 de janeiro de 2019, das estações convencionais de Água Branca (AL), Arcoverde (PE), Cabrobó (PE) e Pão de Açúcar (AL). .....	66
Gráfico 3	- Comparação dos Índices Kappas para os planos de informação (2017 – 2019). .....	116
Gráfico 4	- Comparação das Exatidão Global para os planos de informação (2017 – 2019). .....	116
Gráfico 5	- Comparativos dos intervalos de reflectância para classes de FA, SEXP, CADsarg e CADsaren. ....	129
Gráfico 6	- Comparativos dos intervalos de reflectância para classes de CSEsarg, CSEsaren, ATFA e ATCAD. ....	130
Gráfico 7	- Comparativos dos intervalos de reflectância para classes de MAG. ....	131
Gráfico 8	- Intervalos de NDVI por classe e ano analisado (2017 e 2019). ....	138
Gráfico 9	- Intervalos de SAVI por classe e ano analisado (2017 e 2019).....	138
Gráfico 10	- Intervalos de IAF por classe e ano analisado (2017 e 2019). ....	139

## LISTA DE TABELAS

Tabela 1 - Características das imagens orbitais do satélite CBERS – 4. ....	30
Tabela 2 - Descrição das bandas do satélite CBERS - 4 MUX, com intervalos do comprimento de onda ( $\Delta\lambda$ ), os coeficiente de calibração radiância espectral mínima ( $L_{min\lambda}$ ) e máxima ( $L_{max\lambda}$ ) e a irradiância solar estratosférica média ( $ESUN\lambda$ ).....	73
Tabela 3 - Metadados das imagens usados no projeto da câmera MUX. ....	73
Tabela 4 - Organização dos planos informação.....	77
Tabela 5 - Parâmetros finais de segmentação multirresolução.....	80
Tabela 6 - Número de atributos por plano de informação. ....	82
Tabela 7 - Descrição e ilustração das classes mapeadas na área de estudo. ....	84
Tabela 8 - Número de amostras criadas na geometria de pontos para classificação. ....	86
Tabela 9 - Número de amostras de referência. ....	87
Tabela 10 - Número de amostras por projetos.....	88
Tabela 11 - Interpretação do índice Kappa.....	97
Tabela 12 - Resultados finais da segmentação multirresolução. ....	102
Tabela 13 - Pesos atribuídos aos planos de informação ....	103
Tabela 14 - Proporção da área em hectares (ha) ocupada pelas classes mapeadas. ....	112
Tabela 15 - Percentual de áreas sobrepostas por classe.....	115
Tabela 16 - Teste z para significância entre os índices Kappas resultantes da classificação para as diferentes datas e planos de informação (2017 vs 2019). ....	117
Tabela 17 - Teste z para significância entre os índices Kappas resultantes da classificação para os diferentes planos de informação (2017 vs 2017).....	117
Tabela 18 - Teste z para significância entre os índices Kappa resultantes da classificação para os diferentes planos de informação (2019 vs 2019).....	118
Tabela 19 - Matriz de confusão da classificação do plano de informação I (NIR (8) - R(7) - G(6) - B(5) - PCA (8765) – 2017).....	119
Tabela 20 - Matriz de confusão da classificação do plano de informação II (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF – 2017). ....	119
Tabela 21 - Matriz de confusão da classificação do plano de informação III (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA – 2017). ....	120
Tabela 22 - Matriz de confusão da classificação do plano de informação IV (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA – 2017).....	120
Tabela 23 - Matriz de confusão da classificação do plano de informação V (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) – 2017). ....	121
Tabela 24 - Matriz de confusão da classificação do plano de informação VI (IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF – 2017). ....	121
Tabela 25 - Matriz de confusão da classificação do plano de informação VII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2017). ....	122
Tabela 26 - Matriz de confusão da classificação do plano de informação VIII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2017). ....	122
Tabela 27 - Matriz de confusão da classificação do plano de informação I (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - 2019). ....	123
Tabela 28 - Matriz de confusão da classificação do plano de informação II (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - 2019). ....	123

Tabela 29 - Matriz de confusão da classificação do plano de informação III (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2019). .....	124
Tabela 30 - Matriz de confusão da classificação do plano de informação IV (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2019). .....	124
Tabela 31 - Matriz de confusão da classificação do plano de informação V (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - 2019). .....	125
Tabela 32 - Matriz de confusão da classificação do plano de informação VI (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - 2019). .....	125
Tabela 33 - Matriz de confusão da classificação do plano de informação VII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2019). .....	126
Tabela 34 - Matriz de confusão da classificação do plano de informação VIII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2019). .....	126
Tabela 35 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 5(B) do ano base 2017 (comparação entre classes)....	132
Tabela 36 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 6(G) do ano base 2017 (comparação entre classes)....	133
Tabela 37 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 7(R) do ano base 2017 (comparação entre classes)....	133
Tabela 38 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 8(NIR) do ano base 2017 (comparação entre classes). .....	133
Tabela 39 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 5(B) do ano base 2019 (comparação entre classes)....	134
Tabela 40 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 6(G) do ano base 2019 (comparação entre classes)....	134
Tabela 41 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 7(R) do ano base 2019 (comparação entre classes)....	134
Tabela 42 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 8(NIR) do ano base 2019 (comparação entre classes). .....	135
Tabela 43 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o NDVI do ano base 2017 (comparação entre classes). .....	140
Tabela 44 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o SAVI e IAF do ano base 2017 (comparação entre classe). .....	140
Tabela 45 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o NDVI do ano base 2019 (comparação entre classe). .....	141
Tabela 46 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o SAVI e IAF do ano base 2019 (comparação entre classe). .....	141
Tabela 47 - Resumo estatístico da altura do objetos por classe. ....	145
Tabela 48 - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para MDA (comparação entre classes). .....	145

## LISTA DE ABREVIATURAS E SIGLAS

ALOS	Advanced Land Observation Satellite
ALS	Airborne LiDAR System
ANA	Agência Nacional de Águas
ARFF	Attribute Relation File Format
AT	Área de Transição
AVNIR-2	Advanced Visible and Near Infrared Radiometer type 2
CAD	Caatinga Arbustiva Densa
CAST	Academia Chinesa de Tecnologia Espacial
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
CCD	Câmera Imageadora de Alta Resolução
CGOBT	Coordenação Geral de Observação da Terra
CSE	Caatinga Seca e Esparsa
CSV	Comma Separated Values
DAS	Dia Sequencial do Ano
DBF	Data Base File
DCBD	Descoberta de Conhecimento em Bancos de Dados
DIDGI	Divisão de Geração de Imagens
EG	Exatidão Global
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
$E_p$	Exatidão do Produtor
ERTS	Earth Resources Technology Satellite
ESUN $\lambda$	Irradiância Solar Estratosférica Média
ETM <sup>+</sup>	Enhanced Thematic Mapper Plus
$E_u$	Exatidão do Usuário
EVI	Enhanced Vegetation Index
FA	Floresta de Altitude
FNEA	Fractal Net Evolution Approach
FOM	Floresta Ombrófila Mista
FUNDAJ	Fundação Joaquim Nabuco
GEOBIA	Geographic Object Based Image Analysis
GIS	Geographic Information System
GLCM	Grey Level Co-Occurrence Matrix
HRC	Câmera Pancromática de Alta Resolução
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMBio	Instituto Chico Mendes de Conservação da Biodiversidade
IMFS	Imagem Fusionada
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IRMSS	Imageador por Varredura de Média Resolução
IRS	Imageador Multiespectral e Termal
ISOSEG	Iterative Self-Organization Data Analysis Technique
K	Kappa
KDD	Knowledge Discovery in Databases
$K_p$	Kappa condicional ao produtor

K <sub>u</sub>	Kappa condicional ao usuário
LIDAR	Light Detection and Ranging
MAG	Massas D'Água
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MAXVER- ICM	Máxima Verossimilhança Iterated Conditional Mode
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital do Terreno
MLP	Multilayer PerceptronMulti-Layer Perceptron
MMA	Ministério do Meio Ambiente
MNDWI	Modified Normalized Difference Water Index
MNET	Modelo Numérico de Elevação do Terreno
MODIS	Moderate Resolution Imaging Spectroradiometer
MSS	Multispectral Scanning System
MUX	Câmera Multiespectral Regular
NASA	Administração Nacional da Aeronáutica e Espaço
NASA	Administração Nacional de Aeronáutica e Espaço
NBR	Normalized Burn Ratio
ND	Número Digital
NDBI	Normalized Difference Built-up Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared
NSVDI	Normalized Saturation Value Difference Index
OTB	Orfeo Tool Box
PAN	Câmera Pancromática e Multiespectral
PCA	Análise de Componentes Principais
PDI	Processamento Digital de Imagens
PE3d	Pernambuco Tridimensional PM
PEMP	Parque Estadual Mata da Pimenteira
PNDR	Política Nacional de Desenvolvimento Regional
PRISM	Panchromatic Remote-sensing Instrument for Stereo Mapping
RBV	Return Beam Vidicon
RCS	Substituição de Componente de Proporção
REBIO	Reserva Biológica
RGB	Red, Green, Blue composition
RNA	Rede Neurais Artificiais
RS	Razão Simples
SAAPI	Sistema Aerotransportado de Aquisição e Pós-processamento de Imagens
SAGA	System for Automated Geoscientific Analyses
SAVI	Soil Adjusted Vegetation Index
SEXP	Solo Exposto
SHP	Shapefile
SIRGAS	Sistema de Referência Geocêntrico para as Américas

SNUC	Sistema Nacional de Unidades de Conservação da Natureza
SR	Sensoriamento Remoto
SRHE	Secretaria de Recursos Hídricos e Energéticos
SVM	Support Vector Machine
TM	Thematic Mapper
TOA	Top-Of-Atmosphere
TXT	Arquivo de Texto
UC	Unidade de Conservação
UFCG	Universidade Federal de Campina Grande
UFRJ	Universidade Federal do Rio de Janeiro
UTM	Universal Transversa de Mercator
WEKA	Waikato Environment for Knowledge Analysis
WFI	Câmera de Campo Largo
WFIv	Câmera Imageadora de Amplo Campo de Visada
XLSX	Planilha de cálculo MS Office Open XML
ZA	Zona de Amortecimento
ZP	Zona Primitiva
ZR	Zona de Recuperação
ZUC	Zona de Uso Conflitante
ZUEs	Zonas de Uso Especial
ZUEx	Zona de Uso Extensivo

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>20</b>
<b>2</b>	<b>OBJETIVOS.....</b>	<b>23</b>
2.1	OBJETIVO GERAL.....	23
2.2	OBJETIVOS ESPECÍFICOS.....	23
<b>3</b>	<b>REVISÃO DE LITERATURA.....</b>	<b>24</b>
3.1	SENSORIAMENTO REMOTO.....	24
3.2	SISTEMAS SENSORES.....	26
<b>3.2.1</b>	<b>CBERS – 4.....</b>	<b>28</b>
<b>3.2.2</b>	<b>Light Detection and Ranging (LIDAR).....</b>	<b>31</b>
3.2.2.1	Programa Pernambuco Tridimensional (PE3d).....	31
3.3	COMPORTAMENTO ESPECTRAL.....	32
3.4	ÍNDICES ESPECTRAIS.....	34
3.5	PROCESSAMENTO DIGITAL DE IMAGENS.....	36
<b>3.5.1</b>	<b>Registro de Imagens.....</b>	<b>38</b>
<b>3.5.2</b>	<b>Fusão de Imagens.....</b>	<b>39</b>
<b>3.5.3</b>	<b>Segmentação.....</b>	<b>41</b>
3.5.3.1	Segmentação Multirresolução.....	43
<b>3.5.4</b>	<b>Classificação e Reconhecimento dos Padrões.....</b>	<b>44</b>
3.6	MINERAÇÃO DE DADOS.....	45
<b>3.6.1</b>	<b>Redes Neurais Artificiais (RNA) .....</b>	<b>47</b>
3.6.1.1	Perceptron de Múltiplas Camadas (Multilayer Perceptron- MPL).....	51
3.7	UNIDADES DE CONSERVAÇÃO.....	53
<b>3.7.1</b>	<b>Reserva Biológica de Serra Negra.....</b>	<b>55</b>
3.8	ESTADO DA ARTE.....	56
<b>4</b>	<b>METODOLOGIA.....</b>	<b>60</b>
4.1	ÁREA DE ESTUDO.....	60
4.2	MATERIAL.....	63
4.3	SOFTWARES UTILIZADOS.....	66
4.4	MÉTODOS.....	67
<b>4.4.1</b>	<b>Pré-processamento dos dados.....</b>	<b>69</b>
4.4.1.1	Pré-processamento dos dados: MDT, MDE e Ortoimagens.....	69
4.4.1.2	Pré-processamento dos dados multiespectrais.....	70
4.4.1.2.1	<i>Imagens Reflectância.....</i>	<i>71</i>

4.4.1.2.2	<i>Índices Espectrais: NDVI, SAVI e IAF</i> .....	73
<b>4.4.2</b>	<b>Fusão das bandas do satélite CBERS – 4 MUX/PAN</b> .....	74
<b>4.4.3</b>	<b>Geração das imagens de Análise por Principais Componentes (PCA)</b> .....	76
<b>4.4.4</b>	<b>Planos informação (camadas de entrada)</b> .....	76
<b>4.4.5</b>	<b>Segmentação dos planos de informação</b> .....	77
<b>4.4.6</b>	<b>Seleção dos atributos</b> .....	81
<b>4.4.7</b>	<b>Definição e caracterização das classes mapeadas</b> .....	82
<b>4.4.8</b>	<b>Amostragem</b> .....	85
<b>4.4.9</b>	<b>Mineração dos dados</b> .....	90
4.4.9.1	Preparação dos arquivos entrada para Mineração de Dados.....	90
4.4.9.2	Treinamento da RNA.....	92
<b>4.4.10</b>	<b>Geração dos resultados finais</b> .....	95
<b>4.4.11</b>	<b>Análise de sobreposição de classes</b> .....	96
<b>4.4.12</b>	<b>Análise e avaliação da classificação</b> .....	96
<b>4.4.13</b>	<b>Análises gerais</b> .....	99
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	101
5.1	SEGMENTAÇÃO.....	101
5.2	CLASSIFICAÇÃO DOS DADOS.....	104
5.3	SOBREPOSIÇÃO DE CLASSES.....	114
5.4	AVALIAÇÕES DAS CLASSIFICAÇÕES.....	115
5.5	AVALIAÇÕES E DISCUSSÕES GERAIS.....	128
<b>5.5.1</b>	<b>Bandas multiespectrais</b> .....	128
<b>5.5.2</b>	<b>Índices espectrais</b> .....	135
<b>5.5.3</b>	<b>MDA</b> .....	144
<b>5.5.4</b>	<b>Atributos texturais</b> .....	146
<b>6</b>	<b>CONCLUSÕES E RECOMENDAÇÕES</b> .....	147
6.1	RECOMENDAÇÕES E SUGESTÕES.....	148
	<b>REFERÊNCIAS</b> .....	149

## 1 INTRODUÇÃO

O mapeamento e a classificação de reservas florestais naturais, que estão constantemente em estágio de sucessão ecológica, permite a implantação de diversos estudos e ações para o manejo e uso sustentável das florestas. Nesse sentido, o uso crescente das técnicas de Sensoriamento Remoto tem ganhado destaque para o monitoramento contínuo dessas áreas naturais (DEMARCHI *et al.* 2011). Moreira *et al.* (2016), afirma que essas técnicas de Sensoriamento Remoto passaram a ocupar uma posição central tanto no desenvolvimento científico, como na gestão dos recursos naturais, servindo como ferramenta valiosa para a conservação e monitoramento dos ambientes naturais.

O uso das técnicas de Sensoriamento Remoto para o mapeamento e a classificação das reservas naturais possibilita o conhecimento quantitativo, e qualitativo a respeito da forma e tamanho das áreas ocupadas pela vegetação nativa, bem como sua distribuição espacial (AMARAL *et al.*, 2009). Dentre os métodos tradicionais mais utilizados para a coleta de dados a respeito dessas áreas de reservas naturais, podemos citar o inventário florestal, que é considerado um método bastante trabalhoso, apresenta custos mais elevados, e ainda abrange baixa cobertura de amostragem e frequência (REX *et al.*, 2018). Entretanto, existe um grande esforço na busca de alternativas para otimizar o processo de tomada de decisões para a conservação dessas reservas naturais (CANAVESI *et al.*, 2010)

Nesse contexto, uma alternativa para otimizar a análise de padrões, e identificação de feições (bordas e contornos) de áreas naturais, seria a utilização de imagens digitais proveniente de Sensoriamento Remoto (MENESES; ALMEIDA, 2012). O uso dessas imagens apresenta um baixo custo relativo para os usuários, além de oferecer uma periodicidade quanto a disponibilidade das informações, bem como, a possibilidade da coleta automática de dados para o levantamento e monitoramento contínuos desses ambientes (DEMARCHI *et al.*, 2011; REX *et al.*, 2018). Contudo, o sucesso no mapeamento e classificação de imagens digitais para os ambientes florestais pode ser limitado, devido à grande confusão com outras feições, como por exemplo, solo exposto e pastagens, ocasionado respostas espectrais similares.

Comumente, utiliza-se apenas as informações espectrais radiométricas para classificação de imagens digitais de Sensoriamento Remoto. Porém, o desenvolvimento das técnicas de Sensoriamento Remoto, acompanhado da aquisição de imagens digitais por diferentes sensores (multifontes) tem ganhado interesse pela a comunidade científica, visando estudar a integração dessas diferentes fontes de dados (AMARAL *et al.*, 2009; BRAGA *et al.*,

2015). A utilização de multifontes para o estudo de feições de ambientes naturais torna-se de fundamental importância para esse tipo de mapeamento, devido à similaridade espectral de algumas formações florestais, e a utilização de diferentes sensores, que poderia contribuir para melhorias significativas para discriminação de estratos florestais diferentes com respostas espectrais semelhantes (MENDES e DAL POZ, 2011).

Além das informações espectrais, o uso de informações contendo dados altimétricos, provenientes de técnicas de perfilamento ou varredura a laser podem contribuir para a discriminação de classes de uso e cobertura do solo, como por exemplo, a distinção entre as classes de pastagens, vegetação arbustiva, arbóreas, massa d'água, dentre outros (MENDES e DAL POZ, 2011).

Com a integração de informações altimétricas e espectrais torna-se possível produzir dados complementares para classificação de imagens digitais (SILVA e ARAKI, 2015). Como exemplo, os trabalhos de Piazza (2014); Tedesco *et al.* (2014); e Sothe (2015), utilizando informações espectrais, e altimétricas para a classificação de áreas de estágios sucessionais da vegetação em áreas de Floresta Ombrófila Mista, que obtiveram resultados superiores as classificações puramente baseadas em informações espectrais.

Essa integração de informações espectrais e altimétricas podem ser realizadas utilizando-se método de classificação baseado em técnicas de mineração de dados, como na utilização do algoritmo de Redes Neurais Artificiais (RNA) (MENDES e DAL POZ, 2011; SILVA e ARAKI, 2015). Segundo os autores supracitados, esse método é uma alternativa viável, e interessante para a classificação do uso e cobertura da Terra utilizando imagens digitais de multifontes. A utilização desses métodos emerge como uma alternativa vantajosa em relação aos classificadores de imagens baseados em conceitos estatísticos (Ex.: Máxima Verossimilhança, Distância Mínima), pois permitem a utilização de dados de diferentes origens e escalas (BOTELHO e CENTENO, 2005).

Na classificação baseada por RNA é permitido a incorporação de dados adquiridos por diferentes fontes, mesmo que não apresentem natureza espectral no processo de classificação de imagens (MENDES; DAL POZ, 2011). Neste método, são o arranjo de unidades, e os neurônios interconectados, que trabalham em paralelo para classificar e generalizar os dados de entrada em classes de saída (BOTELHO; CENTENO, 2005). Os métodos de classificação baseados em RNA são capazes de trabalhar com grande quantidade de dados, com diversas características e sofrer pouca influência de ruídos (PEREIRA e CENTENO, 2017). Botelho e Centeno (2005); Chagas *et al.* (2009); Pereira (2011); Mendes e Dal Poz (2011); Pereira e

Centeno (2017), tem aplicado essa técnica para o mapeamento de áreas urbanizadas utilizando imagens de alta resolução espacial e dados de laser scanner.

O bioma da Caatinga apresenta algumas dificuldades técnicas para classificação dos diferentes formações vegetais, utilizando-se dados de sensoriamento remoto (SILVA e CRUZ, 2018), e o emprego desses métodos de integração de múltiplas fontes poderia possibilitar a produção de mapas mais precisos e com um maior nível de detalhamento. Essas dificuldades estão relacionadas principalmente a sazonalidade na disponibilidade hídrica para a vegetação, que durante períodos de estiagem pode ocorrer perda acentuada da folhagem, e em períodos de maior disponibilidade hídrica o aspecto do vegetal muda de forma drástica num curto período de tempo, com o crescimento da nova folhagem (SILVA e CRUZ, 2018). Segundo esses mesmos autores, devido a estas características, o mapeamento deste bioma através de sensoriamento remoto é considerado extremamente complexo, dado que a resposta espectral da vegetação varia de forma significativa em curtos períodos de tempo.

Em particular, a Reserva Biológica de Serra Negra é composta pelo último Remanescente de Mata de Formação Orográfica (Mata Atlântica em meio à Caatinga), apresentam um mosaico de diferentes formações vegetais do bioma Caatinga, e apresentam grandes dificuldades técnicas e processuais para classificação destas áreas. A delimitação de fitofisionomias requer um estudo muito amplo, devido a necessidade de utilizar diferentes imagens, e distintos métodos de processamento para compreensão do comportamento espacial, e espectral dessas áreas em imagens digitais proveniente de sensoriamento remoto (SANTOS, 2012).

A identificação de contornos e bordas em uma imagem de sensoriamento remoto é importante, porque define os limites dos objetos (alvos), e conseqüentemente, o cálculo do perímetro e área dos objetos analisados (ARTERO, 1999). A associação de diferentes fontes de dados, seria uma alternativa viável para discriminar as diferentes fitofisionomias presentes no bioma da Caatinga e avaliar o nível de preservação destes ambientes. O uso desses recursos tecnológicos, auxiliam eficientemente os gestores governamentais durante processo decisório. Já que esse recurso também fomenta estratégias preservacionistas e de recuperação de áreas degradadas, além de servirem como base para a elaboração de novas políticas públicas ambientais, e de novos instrumentos para monitorar os ambientes naturais (BILAR *et al.*, 2018).

## 2 OBJETIVOS

Para o desenvolvimento da presente pesquisa, foram traçados, a seguir, o objetivo geral e os específicos do trabalho.

### 2.1 OBJETIVO GERAL

Integração de imagens de multfontes para o mapeamento de diferentes fitofisionomias de vegetação e áreas antrópicas, presentes na Zona de Amortecimento proposta no plano de manejo da Reserva Biológica de Serra Negra, empregando-se o método de segmentação multirresolução e mineração de dados.

### 2.2 OBJETIVOS ESPECÍFICOS

- Testar o uso de técnicas de segmentação multirresolução e mineração de dados para o mapeamento de fitofisionomias contemplando informações altimétricas, espectrais e temporais;
- Definir os melhores planos de informações para classificação de diferentes fitofisionomias e áreas antrópicas em regiões de transição ecológica e de Mata de Formação Orográfica;
- Analisar e validar os resultados da classificação, e avaliar a influência dos atributos altimétricos (MDA), dos índices espectrais (NDVI, SAVI e IAF) e texturais (entropia e homogeneidade) para o processo de classificação.

### 3 REVISÃO DE LITERATURA

A revisão bibliográfica é apresentada a seguir em diferentes tópicos, a fim de se obter maior clareza e organização dos principais temas abordados na dissertação.

#### 3.1 SENSORIAMENTO REMOTO

A definição clássica do termo sensoriamento remoto (SR) refere-se a um conjunto de tecnologias/técnicas, que permitem à obtenção de informações sobre os objetos que compõem a superfície terrestre, sem que haja contato físico direto com eles (NOVO; PONZONI, 2001, DI MAIO *et al.*, 2008). Esses conjuntos de tecnologias/técnicas envolvem a detecção, aquisição e análise (interpretação e extração de informações) da energia eletromagnética refletida, e/ou emitida pelos objetos que compõem a superfície terrestre que são registradas pelos sensores remotos. A energia eletromagnética, por sua vez, também pode ser denominada de radiação eletromagnética, sendo que ela é emitida por qualquer corpo que possua temperatura acima de zero grau absoluto (0 Kelvin) (DI MAIO *et al.*, 2008).

Todos os corpos que apresentam uma temperatura absoluta acima de zero, podem ser considerados como uma fonte de energia eletromagnética. O Sol e a Terra são as duas principais fontes naturais dessa energia. A quantidade e a qualidade da energia eletromagnética refletida, e emitida pelos objetos terrestre são resultados das interações existentes entre elas (energia eletromagnética x objetos). Dependem das suas propriedades físico-químicas-biológicas, e podem ser identificadas nas imagens e nos dados de sensores remotos (DI MAIO *et al.*, 2008).

Nesse contexto, os sensores remotos são equipamentos capazes de captar a energia eletromagnética (refletida e/ou emitida) originária dos objetos que compõem a superfície terrestre, e convertê-la em sinal elétrico passível de ser anotado, e apresentá-lo em forma adequada à extração das informações (BARROS, SILVA; COSTA, 2016). Estes sensores podem estar acoplados tanto em aeronaves (gerando fotografias aéreas), quanto a bordo de satélites (gerando imagens). Além disso, apresentam capacidade de operar em diferentes faixas do espectro eletromagnético, desde as regiões do visível, até ao infravermelho próximo para fotografias aéreas, e as regiões do visível ao termal para os sensores orbitais (PURIFICAÇÃO; SILVA, 2017).

Atualmente, as técnicas de sensoriamento remoto constituem ferramentas imprescindíveis para o planejamento territorial, sendo largamente utilizadas por geógrafos,

engenheiros, ambientalistas e pesquisadores de várias ciências, possibilitando a análise dos recursos naturais, transportes, comunicações, energia e planejamento urbano e rural (MORATO *et al.*, 2008; PEDRASSOLI, 2011). Aliado a enorme gama de produtos, e informações que podem ser geradas pelas técnicas de sensoriamento remoto, elas também proporcionam baixo custo em relação a outras formas de estudo, que exigem atividades de campo, maior volume de informação ao longo do tempo, além de uma boa qualidade, permitindo a visualização unificada do ambiente, entre outros benefícios (NOVO, 1992; BARROS, *et al.*, 2016).

O surgimento do sensoriamento remoto inicia com o desenvolvimento, e avanço dos estudos da física na óptica, na espectroscopia, na teoria da luz em 1822, pelo francês Niepa que gerou a primeira fotografia. A partir de então, as fotografias sofreram grandes mudanças, e em 1856, outro francês, Tournachon, acoplou uma câmara fotográfica a um balão e fotografou a cidade de Paris, sendo este fato o marco inicial da fotografia aérea. E com o aparecimento dos aviões, as fotografias aéreas foram largamente utilizadas para fins cartográficos, principalmente na área militar (INPE, 1998; BARROS, *et al.*, 2016).

O termo sensoriamento remoto surgiu na literatura científica nos anos 60, referindo-se a utilização de sensores capazes de captar a energia eletromagnética refletida e/ou emitida, total e/ou parcialmente pelos objetos, e feições naturais que compõem a superfície terrestre (PEDRASSOLI, 2011). Nesta época, iniciaram-se também os investimentos no Brasil, e a capacitação de profissionais para o desenvolvimento de infraestrutura, que viabilizassem a aplicação das técnicas de sensoriamento remoto, com a implantação do Projeto Sensoriamento Remoto no Instituto de Pesquisas Espaciais (NOVO; PONZONI, 2001).

Inicialmente, em meados dos anos 70, as atividades de sensoriamento remoto no Brasil, se concentravam na recepção, e na utilização de imagens orbitais do sensor Multispectral Scanning System (MSS) da série dos satélites LANDSAT (1 a 3), restringindo a viabilização da identificação de feições específicas existentes na superfície terrestre que, por sua vez, possibilitaram a elaboração de mapas temáticos variados do país. Posteriormente, com o lançamento do sensor Thematic Mapper (TM) a bordo do satélite LANDSAT 4 e LANDSAT 5, na década de 80 ocorreram as melhorias na resolução espacial, e o maior número de faixas espectrais exploradas pelo sensor em relação ao seu anterior MSS. Assim, surgiram novas possibilidades de aplicação de técnicas de sensoriamento remoto, incluindo não só apenas os mapeamentos temáticos, mas também os estudos visando à quantificação de parâmetros biofísicos, mediante ao uso dos dados radiométricos derivados das imagens geradas (NOVO; PONZONI, 2001).

O primeiro satélite, cujo objetivo principal era atuar diretamente em pesquisas de recursos naturais foi lançado em 1972, desenvolvido pela Administração Nacional de Aeronáutica e Espaço (NASA) dos Estados Unidos, que possuía a missão denominada de Earth Resources Technology Satellite – 1 (ERTS - 1), e posteriormente em 1975 passou a se chamar LANDSAT - 1. Este satélite levou a bordo dois instrumentos, sendo eles; as câmeras RBV (Return Beam Vidicon) e MSS (Multispectral Scanner System), e operou por um período de cinco anos. Desde o desenvolvimento do primeiro LANDSAT - 1, foram lançados mais sete satélites (LANDSAT – 2, 3, 4, 5, 6, 7 e o atual 8), todos com imagens multiespectrais, e adquirindo milhares de imagens da superfície terrestre repetidamente (NASA, 2010; 2015; INPE, 2016). No Brasil, a principal série de satélites desenvolvidos pelo país em parceria com a China, a fim de observar a superfície terrestre foi denominada de CBERS (Satélite Sino-Brasileiro de Recursos Terrestres), e já foram lançados cinco sensores para órbita terrestre.

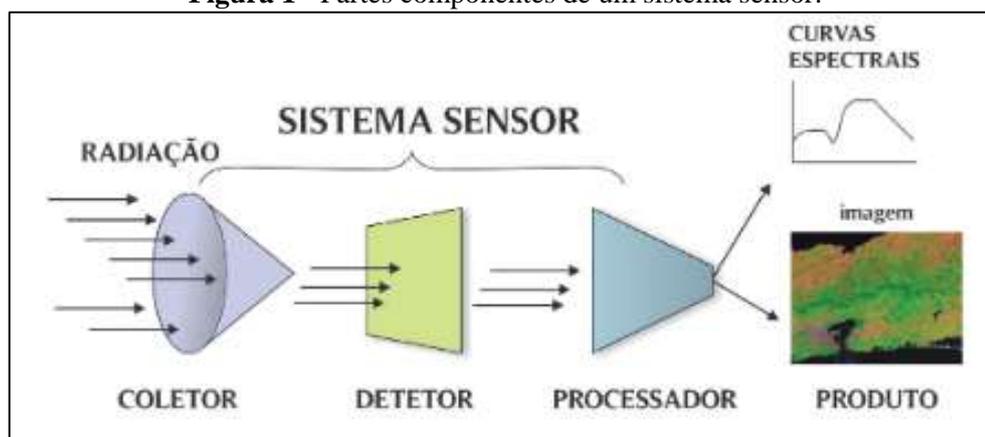
Ao longo dos anos desenvolveram-se várias séries de satélites, e câmeras em diferentes países para observação da Terra. O desenvolvimento desses instrumentos (sensores remotos) permitiu a aplicação em diferentes áreas do conhecimento, sendo fundamentais e indispensáveis no mapeamento, e monitoramento de recursos naturais. As vantagens da utilização da tecnologia de sensoriamento remoto consistem em possibilitar a obtenção de informações antigas, e/ou atualizadas com frequência, devido ao desenvolvimento de novos sensores, e a existência de uma ampla gama de programas espaciais voltados à obtenção de dados para estudos dos recursos naturais. A observação da Terra por meio dos sensores remotos é uma forma eficaz, e econômica de coletar os dados necessários para monitorar, e modelar os fenômenos que ocorrem na superfície terrestre, especialmente em países de grande extensão territorial, como o Brasil (NOVO; PONZONI, 2001; DI MAIO *et al.*, 2008; PEDRASSOLI, 2011).

### 3.2 SISTEMAS SENSORES

Conforme já descrito na seção anterior, os sensores remotos são equipamentos capazes de colher a energia eletromagnética (refletida e/ou emitida) originária dos objetos que compõe a superfície terrestre, e convertê-la em sinais elétricos passíveis de serem registrados, e apresentá-los de forma adequada para a extração das informações (BARROS, SILVA; COSTA, 2016). Estes sensores podem ser acoplados em plataformas orbitais (com câmeras, “scanners” e radares dos satélites), aéreas de alta ou baixa altitude (aeronaves) e terrestre (radiômetros e

espectrorradiômetro). O sistema sensor (Figura 1) é constituído basicamente por um **coletor**, que recebe a energia através de um conjunto lente, espelho ou antenas, o **detetor** que capta a energia coletada de uma determinada faixa do espectro, e pelo **processador** que processa o sinal registrado (revelador, amplificação, entre outros) através do qual se obtém o produto (CAMARA *et al.*, 1996).

**Figura 1** - Partes componentes de um sistema sensor.



Fonte: Modificado por Moreira (2001).

Os sensores podem ser classificados em função da fonte de energia, ou do tipo de produto que produz (existindo outras classificações, mas estas são as mais importantes). Em função da fonte de energia, os sensores podem ser classificados, como; **passivos** que são aqueles sensores que não possuem fonte própria de radiação, e que mede a radiação solar (energia eletromagnética) refletida e/ou emitida pelos alvos terrestres, como por exemplo, os satélites da série LANDSAT e CBERS; já os sensores **ativos** possuem sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro como, por exemplo, os satélites Radarsat e Jers-1. Os sensores passivos, e ativos também podem ser agrupados em duas categorias; de varredura (scanning) ou de não-varredura (non scanning) (CAMARA *et al.*, 1996).

Em função do tipo de produto gerado, os sensores também podem ser classificados como: **não-imageadores**, pois não geram a imagem da superfície sensoriada, como por exemplo, espectrorradiômetros (assinatura espectral) e radiômetros (saída em dígitos, ou gráficos), que geralmente são utilizados essencialmente para aquisição de informações precisas sobre o comportamento espectral dos objetos. E os sensores **imageadores** obtém uma imagem da superfície observada como resultado, e geralmente fornecem as informações sobre a variação espacial da resposta espectral da superfície observada, como por exemplo, os satélites CBERS, LANDSAT, Spot e Ikonos (SPRING, 2006).

Os sistemas de sensores imageadores podem ser divididos em; **sistemas de quadro** ("framing systems"), que adquirem a imagem da cena em sua totalidade no mesmo instante (Ex.: RBV); e **sistema de varredura** ("scanning systems"), cuja imagem da cena observada é formada pela aquisição sequencial de imagens elementares da superfície (Ex.: TM, MSS, HRV); e pelo **sistema fotográfico** que possui a capacidade de observar as respostas espectrais, cobrindo apenas o espectro eletromagnético entre o ultravioleta próximo ao infravermelho distante (Ex.: câmeras aerotransportados) (CAMARA *et al.*, 1996).

A utilização de sistemas sensor ativos possui como principais vantagens, a obtenção das medidas a qualquer momento do tempo (dia), e não depende da luz solar, porém como desvantagem precisa gerar uma grande quantidade de energia para manter o funcionamento, e sua análise é mais complicada e de alto custo. A utilização de sistemas sensor passivos tem como principais vantagens, reunir simultaneamente várias bandas espectrais estreitas, o que permite numerosas interpretações, além de ser mais fácil de ser trabalhada. Entretanto, como desvantagem não emite sua própria radiação, e os alvos necessitam do recebimento de luz natural e/ou radiação (proveniente do sol principalmente), e costuma operar durante apenas um período do dia, e as condições atmosféricas podem interferir muito na geração dos produtos (CAMARA *et al.*, 1996; FIDALGO *et al.*, 2013).

A respeito dos sistemas de sensores que deverão ser utilizados na pesquisa, nas próximas seções serão discutidas um pouco sobre eles, sendo o sensor passivo representado pelo CBERS – 4, na qual serão utilizadas as imagens pancromáticas e multiespectrais, e também a utilização de um sensor e ativos LIDAR na qual foi utilizado para elaboração dos modelos digitais de superfície do PE3D.

### **3.2.1 CBERS – 4**

Em 06 de julho de 1998, os governos do Brasil, e da China assinaram um acordo de parceria entre o Instituto Nacional de Pesquisas Espaciais (INPE), e a Academia Chinesa de Tecnologia Espacial (CAST) para o desenvolvimento de um programa para construção de dois satélites avançados de sensoriamento remoto de nível internacional, denominado Programa CBERS (China-Brazil Earth Resources Satellite, e Satélite Sino-Brasileiro de Recursos Terrestres) (EMBRAPA, 2014). Devido ao grande sucesso do CBERS - 1 e 2, os dois governos decidiram dar continuidade ao Programa CBERS firmando um novo acordo, em novembro de

2002, para o desenvolvimento e lançamento de mais dois satélites, os CBERS-3 e 4 (INPE, 2018).

Entretanto, o desenvolvimento, e o lançamento do CBERS - 3 era viável apenas para o horizonte de planejamento em que o CBERS - 2 já tivesse deixado de funcionar, com prejuízo para ambos os países e para os inúmeros usuários do CBERS. Então, em 2004, os governos do Brasil e da China decidiram construir o CBERS - 2B e lançá-lo em 2007, que permaneceu operante até o começo do ano de 2010. O CBERS - 3 foi lançado em 09 de dezembro de 2013, e devido a uma falha ocorrida com o veículo lançador Longa Marcha 4B, o satélite não foi colocado na órbita prevista, resultando em sua reentrada na atmosfera terrestre. Após a falha no lançamento do CBERS - 3, os governos do Brasil e da China decidiram antecipar o lançamento do CBERS - 4 em um ano, sendo lançado em 07 de dezembro de 2014 com sucesso (EMBRAPA, 2014).

As séries de satélites CBERS possuem um conjunto de diversos sensores, e/ou instrumentos com alto potencial para atender as múltiplas aplicações em sensoriamento remoto. Esta série de satélites CBERS se enquadra na classificação quanto a sua fonte de energia de sensores passivos, e como sensores imageadores do sistema quadro quanto a sua classificação em relação do tipo de produto gerado. A primeira geração de satélites CBERS (1, 2 e 2B) ao longo dos 16 anos de desenvolvimento passou por uma evolução, e a segunda geração do CBERS - 3 e 4 agregaram as melhores características de sensores orbitais para o mapeamento terrestre desenvolvido pelo INPE e pela CAST. Nesse contexto, a primeira geração de satélites CBERS tinha como carga útil três câmeras imageadoras: a Câmera Imageadora de Alta Resolução (CCD); Imageador por Varredura de Média Resolução (IRMSS); Câmera Imageadora de Amplo Campo de Visada (WFIv) para o CBERS 2B, e a câmera IRMSS dos satélites CBERS - 1, 2 foi substituída pela Câmera Pancromática de Alta Resolução (HRC). Já para a segunda geração do CBERS (3 e 4) utilizaram no seu módulo de carga útil quatro câmeras imageadoras: a Câmera Pancromática e Multiespectral (PAN); Câmera Multiespectral Regular (MUX); Imageador Multiespectral e Termal (IRS); e a Câmera de Campo Largo (WFI), com alto desempenhos geométricos e radiométricos (INPE, 2018). As principais características do CBERS - 4 encontram-se apresentadas na Tabela 1 a seguir.

**Tabela 1** - Características das imagens orbitais do satélite CBERS – 4.

Satélite / Sensor	Bandas	Resolução Espacial	Período de Revisita	Faixa Imageada
CBERS / PAN	B01: 0,51 - 0,85 $\mu\text{m}$ (PAN)	5 m	52 dias	60 km
	B02: 0,52 - 0,59 $\mu\text{m}$ (G)	10 m		
	B03: 0,63 - 0,69 $\mu\text{m}$ (R)			
	B04: 0,77 - 0,89 $\mu\text{m}$ (NIR)			
CBERS / MUX	B05: 0,45 - 0,52 $\mu\text{m}$ (B)	20 m	26 dias	120 Km
	B06: 0,52 - 0,59 $\mu\text{m}$ (G)			
	B07: 0,63 - 0,69 $\mu\text{m}$ (R)			
	B08: 0,77 - 0,89 $\mu\text{m}$ (NIR)			
CBERS / IRS	B09: 0,50-0,90 $\mu\text{m}$ (PAN)	40 m	26 dias	120 Km
	B10: 1,55-1,75 $\mu\text{m}$ (SWIR)			
	B11: 2,08-2,35 $\mu\text{m}$ (SWIR)	80 m		
	B12: 10,40-12,50 $\mu\text{m}$ (TH)			
CBERS / WFI	B13: 0,45 - 0,52 $\mu\text{m}$ (B)	64 m	5 dias	866 km
	B14: 0,52 - 0,59 $\mu\text{m}$ (G)			
	B15: 0,63 - 0,69 $\mu\text{m}$ (R)			
	B16: 0,77 - 0,89 $\mu\text{m}$ (NIR)			

\* R – canal vermelho; G – canal verde; B – canal azul; NIR – canal do infravermelho-próximo; PAN - banda pancromática; SWIR - infravermelho de ondas curtas; TH – banda Termal;  $\mu\text{m}$  – unidade de medida em micrômetro.

Fonte: Adaptada do INPE, 2018.

Segundo o INPE (2018), o potencial de aplicação do sensor é estabelecido em função de suas características de resolução espacial, resolução temporal, características espectrais e radiométricas. A gama de produtos que podem ser elaborados, ou observados pelas câmeras da série de satélites CBERS abrange um universo muito amplo de aplicações, destacando-se para as câmeras CCD, HRC, PAN e MUX, por exemplo, para o estudo sobre a vegetação, água, solo, agricultura, cartografia e geologia. Já as câmeras IRMSS tem um enorme potencial para análise de fenômenos, que apresentam alterações de temperatura da superfície terrestre, na geração de mosaicos estaduais, e na geração de cartas-imagens. A câmera WFI pode imagear grandes extensões territoriais, sendo aplicada principalmente para a geração de mosaicos nacionais ou estaduais, geração de índices de vegetação para fins de monitoramento e fenômenos dinâmicos, como safras agrícolas, e queimadas persistentes (INPE, 2018).

### ***3.2.2 Light Detection and Ranging (LIDAR)***

Os sensores de tecnologia LIDAR (Light Detection and Ranging) são sensores remotos ativos a qual podem estar a bordo de plataformas orbitais (tripuladas ou não tripuladas) ou a bordo de aeronaves. Dessa forma, utiliza-se o método direto para captura dos dados, e o mesmo possui sua própria fonte de energia, sendo para esse caso, o laser como fonte de luz. Esse tipo de sistema permite que o LIDAR emita feixes de laser na banda do infravermelho próximo (IV), possuindo capacidade de modelar a superfície do terreno tridimensionalmente, assim esse processo também é conhecido como perfilamento ou varredura a laser (COLAÇO *et al.*, 2015; INPE, 2017). Essa forma de levantamento coleta uma grande quantidade de pontos chamada nuvem de pontos, que permitem a geração do Modelo Digital de Terreno e Modelo Digital de Superfície, que representam o terreno (sem a cobertura) e a superfície (vegetação, edificações, entre outros), respectivamente (INPE, 2017).

A técnica de imageamento direto por LIDAR, consiste na medição do tempo de ida, e volta da energia de um pulso a laser entre o sensor e o alvo. Este pulso incidente de energia interage com superfícies dos alvos (solo, água, vegetação, entre outros) retornando ao instrumento (PIRES, 2005). Essa técnica de sensoriamento remoto foi disseminada, e aplicada principalmente pela indústria, e tem sido investigada para agricultura de precisão (COLAÇO *et al.*, 2015). A técnica LIDAR foi utilizada para elaboração do projeto do Programa Pernambuco Tridimensional.

#### **3.2.2.1 Programa Pernambuco Tridimensional (PE3d)**

Após a ocorrência das enchentes que atingiram drasticamente os municípios da Mata Sul do Estado de Pernambuco, entre os anos 2010 e 2011, surgiu o Projeto para o mapeamento do território pernambucano, o Pernambuco Tridimensional (PE3d). Inicialmente, foram mapeadas as áreas afetadas, e da calha dos principais rios das bacias hidrográficas atingidas pelas enchentes, sendo realizada pela Secretaria de Recursos Hídricos e Energéticos (SRHE) do estado. O mapeamento foi realizado por varredura a laser do terreno, utilizando a tecnologia LIDAR e recobrimento aerofotogramétrico, que permitiu a obtenção com rapidez, e qualidade das informações altimétricas para elaboração dos projetos das barragens de controle de cheias,

além de gerar os sistemas de prevenção e alerta de inundações para a bacia do Rio Una (CIRILO, 2015; PE3d, 2016; LIMA *et al.*, 2018; LINS, 2018).

Posteriormente, o mapeamento foi ampliado para todo o estado de Pernambuco, originando uma base de dados espaciais para apoiar o planejamento territorial (LIMA *et al.*, 2018). O mapeamento compreendeu todos os serviços de recobrimento aerofotogramétrico e perfilamento a laser (LINS, 2018). O conjunto de dados encontra-se disponibilizados exclusivamente em meio digital, e todo o conteúdo é oferecido integralmente para download (PE3d, 2016). Os principais produtos gerados pelo mapeamento foram: Modelo Digital de Elevação (MDE), Modelo Digital do Terreno (MDT) e Ortoimagem, em paralelo ao mapeamento está sendo realizada a implantação de marcos geodésicos dentro do território pernambucano.

Esse levantamento permitiu que o estado de Pernambuco pudesse obter uma notável base de dados espaciais, concedendo suporte a muitas iniciativas de desenvolvimento sustentável dos municípios. São cerca de 75 bilhões de pontos amostrados com as coordenadas planimétricas e altimétricas, representando uma densidade de pontos 1,3 m<sup>2</sup> de todo o território pernambucano. Assim, todos os produtos gerados foram referenciados no Sistema de Coordenadas Projetadas UTM SIRGAS 2000, nos fusos 24S ou 25S. A gama de produtos do PE3d possuem um enorme potencial para utilização nos empreendimentos públicos, e privados de maior porte (PE3d, 2016).

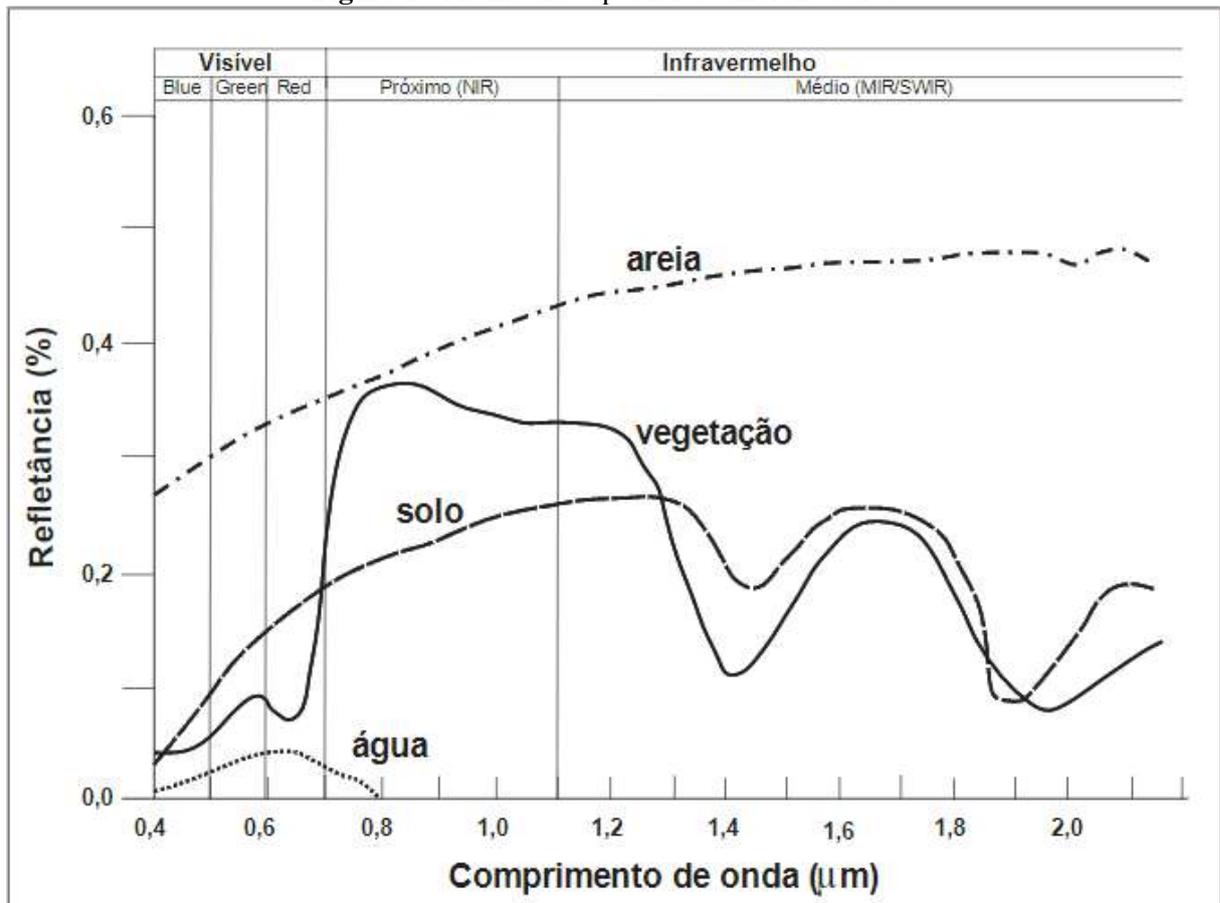
### 3.3 COMPORTAMENTO ESPECTRAL

Os alvos terrestres quando observados por sensores remotos apresentam aparência que depende da relação deles com a energia incidente. O sol é a principal fonte natural de radiação, que através das ondas eletromagnética chega a Terra, interagem com os alvos (vegetação, solo, água e outros materiais) ocorrendo simultaneamente os processos de absorção, reflexão e transmissão. Essas interações acontecem de maneira complexa, e depende das características biofísicas e químicas dos alvos (FLORENZANO, 2011), além de ocorrerem com intensidades diferentes em diferentes regiões do espectro eletromagnético, determinando o seu comportamento espectral (DI MAIO *et al.*, 2008; SILVA, 2012).

O comportamento espectral de um objeto (alvo) pode ser definido como sendo um conjunto dos valores específicos da reflectância do objeto dentro do espectro eletromagnético (Figura 2), também conhecido como a assinatura espectral do objeto (MORAES, 2001). De

acordo com Pacheco *et al.* (2006), a assinatura espectral permite ao sensoriamento remoto distinguir os diversos materiais ou alvos entre si. O comportamento espectral também pode definir os limites das feições, sendo que a forma, a intensidade e a localização de cada banda de absorção é que caracteriza o objeto (MORAES, 2001).

**Figura 2 - Assinatura espectral de diferentes alvos.**



Fonte: Adaptado de NOVO (2010).

Além dos fatores biofísicos e químicos dos alvos, o comportamento espectral também é influenciado pelo método de aquisição dos dados, geometria do imageamento, parâmetros atmosféricos e parâmetros relativos a textura, densidade e posição relativa dos alvos em relação ao ângulo de incidência solar (PACHECO *et al.*, 2006). De acordo com Novo (1989), o conhecimento do comportamento espectral dos alvos sobre a superfície terrestre é fundamental para a extração de informações a partir de dados de imagens orbitais, assim como os fatores que interferem neste comportamento.

Neste contexto, percebe-se que tem crescido o número de pesquisas para avaliar o comportamento espectral dos alvos, com intuito de diferenciar as espécies vegetais por meio da curva espectral e outros recursos provenientes de sensoriamento remoto (MAGALHÃES;

XAVIER, 2018). Como exemplo, os trabalhos de Naue *et al.* (2011), que analisaram as respostas espectrais de espécies da Caatinga utilizando um espectrorradiômetro. Magalhães *et al.* (2013), realizaram análises multitemporais para avaliar a dinâmica vegetal de Floresta Estacional Submontana, Floresta Estacional Semidecidual e cana-de-açúcar utilizando imagens do sensor *Thematic Mapper* (TM) do satélite LANDSAT – 5.

Cicerelli e Galo (2015), avaliaram o potencial de dados espectrais de multifonte na detecção remota do fitoplâncton utilizando imagens multiespectrais do satélite MODIS e RapidEye. Entre os estudos que além de analisar o comportamento espectral também levaram em conta os aspectos altimétricos dos alvos podem ser citados os trabalhos de Mendes e Dal Poz (2011); Silva e Araki (2015); e Pereira e Centeno (2017).

### 3.4 ÍNDICES ESPECTRAIS

De acordo com Tolentino (2019), os índices espectrais são utilizados com o objetivo de realçar alvos específicos, conforme as suas respostas espectrais. Segundo esse mesmo autor, esses índices podem ser obtidos a partir da combinação entre duas, ou mais bandas espectrais envolvendo faixas de reflectância específicas que possibilitam a diferenciação dos alvos. Silva (2012), afirma que os índices espectrais para a vegetação auxiliam muito na interpretação de imagens e no processo de classificação, eliminando ou minimizando as limitações apresentadas pelo sensoriamento remoto na distinção de alvos na superfície terrestre.

Na literatura, diversos índices são propostos, dentre eles podemos citar para vegetação: *Normalized Difference Vegetation Index* (Índice de Vegetação de Diferença Normalizada - NDVI); *Soil Adjusted Vegetation Index* (Índice de Vegetação Ajustada do Solo - SAVI); *Enhanced Vegetation Index* (Índice de Vegetação Aprimorado - EVI); *Leaf Area Index* (Índice de Área Foliar - IAF) e *Green Chlorophyll Index* (Índice de Clorofila Verde - GCI); e para água: *Normalized Difference Water Index* (Índice de Diferença Normalizada da Água - NDWI) e *Modified Normalized Difference Water Index* (Índice de Diferença Normalizada de Água Modificado - MNDWI); e para áreas construídas: *Normalized Difference Built-Up Index* (Índice de Áreas Construídas por Diferença Normalizada - NDBI); para áreas queimadas *Normalized Burn Ratio* (Taxa de Queima Normalizada - NBR), e para identificação de áreas sombreadas *Normalized Saturation Value Difference Index* (Índice de Diferença do Valor de Saturação Normalizado - NSVDI), dentre outros.

De acordo com Fuller (2001) a utilização desses índices têm ajudado significativamente no estudo de áreas florestadas, especialmente em regiões que possuem fragmentos florestais dinâmicos. Segundo esse mesmo autor, esses índices também ajudam na análise do comportamento da vegetação em locais que sofrem constantemente interferências antrópicas, incluindo áreas que estão sendo submetidas ao avanço da urbanização. A utilização do sensoriamento remoto possui um papel importante nos estudos da vegetação, assim sendo, os pesquisadores vem desenvolvendo vários índices de vegetação ao longo dos anos para monitorar e quantificar as condições e distribuições das áreas de vegetação, a partir de imagens de reflectância espectral (LIU, 2007).

Para esta pesquisa optou-se pela utilização do Índice de Vegetação de Diferença Normalizada (NDVI), Índice de Vegetação Ajustada do Solo (SAVI) e Índice de Área Foliar (IAF). Tais índices foram utilizados para facilitar a obtenção e a modelagem dos parâmetros biofísicos da vegetação, como a área foliar, biomassa e a porcentagem de cobertura do solo, com destaque para a região do espectro eletromagnético do infravermelho, que pode fornecer importantes informações sobre a evapotranspiração das plantas (EPIPHANIO *et al.*, 1996; JENSEN, 2009; e BORATTO; GOMIDE, 2013). Os demais índices, como o GCI, NDWI, MNDWI, NDBI, NBR, e NSVDI não foram utilizados, devido à falta ou a inexistência de áreas de grandes corpos hídricos, áreas queimadas, construídas e sombreadas.

O NDVI foi proposto por Rouse *et al.* (1973), para minimizar os efeitos causados pelo relevo, e pela interferência do solo na resposta da vegetação. Tal índice também pode ser considerado como um importante indicador sensível da quantidade e condição da vegetação, estando ligado diretamente ao tipo, a densidade e umidade da superfície (BORATTO; GOMIDE, 2013). O SAVI foi proposto por Huete (1988), visando uma modificação do NDVI com intuito de minimizar os efeitos da variabilidade, do tipo e densidade da vegetação. De acordo com Jansen (2009), a capacidade desse índice de minimizar os “ruídos” do solo, favoreceu a sua aplicabilidade em diversas pesquisas para áreas vegetadas.

O IAF é um índice biofísico definido pela razão entre a área foliar de uma vegetação por unidade de área utilizada por esta vegetação, sendo um indicador da biomassa de cada pixel da imagem digital. O IAF vem sendo usado como indicador da produtividade florestal, e possui grande aplicabilidade para a identificação e evolução das condições ambientais de fragmentos florestais (BERGER *et al.*, 2019; GUIMARÃES *et al.*, 2012).

Estes índices são amplamente utilizados em estudos de integração multitemporal e multisensores para classificação de uso e cobertura do solo, como exemplo, nos trabalhos de

Silva (2012), Bento (2017); Tolentino (2019) e Baeza; Paruelo (2020). Recentemente Lopes *et al.* (2020), realizaram um trabalho de revisão bibliográfica sobre o uso dos índices de vegetação no estudo da dinâmica e da degradação da cobertura vegetal nos domínios das Caatingas, e constatou uma grande diversidade de trabalhos envolvendo esta temática, utilizando diferentes sensores, diferentes épocas e resoluções espaciais.

Carvalho (2016), avaliou o IAF em uma área de Caatinga preservada, com medidas *in situ* e posteriormente avaliou sua correlação com índices espectrais (NDVI, SAVI e IAF), utilizando imagens orbitais. No estado de Pernambuco, Oliveira (2013), utilizou índices de vegetação (NDVI, IVAS, IAF, NDWI) para subsidiar à gestão do uso e ocupação do solo para zona de amortecimento da Reserva Biológica de Saltinho. Figueirêdo *et al.* (2013), avaliaram a cobertura vegetal para a bacia do Alto Ipanema no agreste pernambucano, por meio de índices de vegetação utilizando técnicas de sensoriamento remoto.

### 3.5 PROCESSAMENTO DIGITAL DE IMAGENS

Segundo Leite *et al.* (2012), a utilização das imagens obtidas por meio das técnicas sensoriamento remoto é realizada através da técnica de Processamento Digital de Imagens (PDI), que por sua vez, tem a finalidade de facilitar a análise e a interpretação das imagens para melhor o entendimento do usuário. De acordo com Crósta (1992), o PDI foi definido como a análise e manipulação de imagens em meio digital (computador), cuja finalidade consiste em identificar, e extrair informações da imagem transformando-a de tal modo que a informação seja mais facilmente discernível por um analista humano.

As imagens digitais, por sua vez, são constituídas por um conjunto discreto de elementos pictóricos denominados de pixels, que se distribuem ao longo de uma grade regular. Essas imagens são representadas geralmente por uma matriz, ou por uma função bidimensional discreta e não negativa, que assume valores não nulos apenas em um conjunto finito de pontos. Para cada pixel são associados valores numéricos, que representa o nível de luminosidade, ou reflectância médio de uma região do espectro eletromagnético. Esses valores geralmente são representados graficamente pelo nível de cinza, que podem variar entre o branco até o preto (COSTA, 1998).

Nas imagens de sensoriamento remoto de superfície terrestre, como por exemplo, as imagens dos satélites LANDSAT e CBERS, cada pixel está associado a valores numéricos denominado de Número Digital (ND) ou Digital Number (DN), que indica o nível de cinza. O

ND de cada pixel corresponde à intensidade de radiância (descretização da radiância) pela superfície terrestre, e passando por um PDI, este número poderá representar à intensidade da energia eletromagnética refletida ou emitida pelos alvos. Já nos sensores LIDAR, por exemplo, cada pixel da imagem (modelo digital de superfície ou terreno) gerada por essa técnica, geralmente representa um valor altimétrico. Os pixels das imagens digitais também podem representar outras variáveis, como por exemplo, variáveis meteorológicas como; temperatura, precipitação, umidade, entre outros (COSTA, 1998; SPU, 2017).

Como regra, geralmente os pixels com níveis de cinza mais claros apresentam valores mais altos, e níveis de cinza mais escuros apresentam valores mais baixos, assim essa distinção pode facilitar a análise e interpretação das imagens. Atrelado a isso, outra característica também importante de ser conhecida sobre os pixels é a quantidade, e o nível de detalhes preservados na representação da imagem digital (COSTA, 1998). A quantidade, e o nível de detalhes presentes nas imagens digitais utilizadas em sensoriamento remoto, auxiliam no reconhecimento das características da resolução espacial, espectral, radiométrica e temporal.

A resolução espacial refere-se a capacidade do sensor de enxergar objetos ou alvos na superfície, ou seja, mede a menor separação angular ou linear entre dois objetos (a grosso modo, seria qual a área representada por cada pixel da imagem). Diante disso, quanto menor o tamanho de um pixel representando um objeto e/ou alvo, maior será sua resolução espacial, tornando o objeto mais identificável, ou melhor discriminado. Porém, isso pode resultar em um volume muito grande de informação, e demandar maior capacidade de processamento (CAMARA *et al.*, 1996; SPU, 2017).

A resolução espectral consiste na medição do número, e do tamanho do intervalo do comprimento de onda (denominado de bandas) no espectro eletromagnético ao qual o sensor é sensível (JENSEN; EPIPHANIO, 2011). Os sensores multiespectrais, como por exemplo, da série LANDSAT e CBERS, são sensíveis a múltiplas bandas do espectro eletromagnético (geralmente entre as bandas do azul ao infravermelho termal), já os sensores hiperespectrais, a exemplo o AVIRIS podem adquirir dados em centenas de bandas espectrais (CAMARA *et al.*, 1996; SPU, 2017).

A resolução radiométrica refere-se à maior, ou menor capacidade do sistema sensor em detectar e registrar diferenças na energia refletida, e/ou emitida pelos alvos que compõe a cena, ou seja, está associada à sensibilidade do sistema sensor em distinguir dois níveis de intensidade do sinal de retorno (a grosso modo, é a capacidade de registrar os níveis de cinza) (CAMARA *et al.*, 1996; DIMAIO *et al.*, 2008; SPU, 2017). Essa resolução nas imagens digitais

de sensoriamento remoto pode influenciar na capacidade de medir as pequenas variações na intensidade da radiância medida pelo sensor (NOVO; PONZONI, 2001).

A resolução temporal refere-se ao intervalo de tempo em que o sensor leva para reamostrar uma determinada imagem de um local, ou seja, é a frequência com que a superfície terrestre é observada ou imageada. A resolução temporal pode influenciar na qualidade das imagens digitais de sensoriamento remoto, pois de acordo com os intervalos das estações do ano (período seco ou chuvoso) em que as imagens foram, ou serão obtidas pode ocorrer a presença de nuvens e/ou de outros fenômenos climáticos inviabilizando as cenas para análise e interpretação (DI MAIO *et al.*, 2008; SPU, 2017).

Para analisar as imagens digitais de sensoriamento remoto faz-se o uso de técnicas PDI, que possibilitam a integração de vários tipos de dados, devidamente georeferenciados, e nas diferentes regiões do espectro eletromagnético. O processamento de imagens pode-se dividir em três etapas principais; sendo que a primeira parte realiza o pré-processamento das imagens (cena trabalhada), que consiste no processamento inicial de dados brutos para calibração radiométrica, correção de distorções geométricas e remoção de ruído. A segunda etapa seria a aplicação de realce visando melhorar a qualidade visual da imagem, o que poderia permitir uma melhor discriminação dos objetos presentes na cena. Já a terceira parte está relacionada à classificação da imagem, atribuindo a ela as classes às quais os objetos presentes pertencem, como por exemplo, as classes de solo, água e vegetação (CAMARA *et al.*, 1996), porém outros procedimentos também poderão ser adotados.

De acordo com Esquef *et al.* (2003), o sistema de processamento de imagens é mais abrangente e composto por diversas etapas, tais como: formação e aquisição da imagem, digitalização, pré-processamento, segmentação, fusão de imagens, pós-processamento, extração de atributos, classificação e reconhecimento. No PDI visando a integração de diferentes sensores (multifontes) para o mapeamento de fitofisionomias, algumas das principais etapas são: o registro da imagens, fusão de imagens, segmentação, classificação e reconhecimento dos padrões.

### **3.5.1 Registro de Imagens**

No sensoriamento remoto, comumente torna-se necessário comparar e analisar imagens multitemporais e/ou combinar e analisar imagens de diferentes sensores de uma mesma área, tornando a justaposição das imagens necessárias. Nesses casos, é preciso assegurar que os

pixels da imagem a ser processada estejam relacionados à mesma área do terreno, o que dificilmente ocorrerá, mesmo considerando um mesmo sensor, a bordo de um mesmo satélite, dadas as distorções não sistemáticas causadas pelo movimento do satélite. Portanto, antes de fundir/comparar duas imagens de uma mesma área, é necessário que ambas estejam perfeitamente registradas entre si (ERBEK *et al.* 2004; SILVA, 2012).

Em PDI, o registro de imagens pode ser entendido como um processo que envolve a sobreposição de uma mesma cena aparecendo em duas ou mais imagens diferentes, de forma que os pontos correspondentes nessas imagens coincidam no espaço geográfico (CRÒSTA, 1992). O resultado da correção geométrica do registro deve obter um erro dentro de cerca de um pixel de sua posição real, de modo que permita as avaliações, e a medição espacial precisa dos resultados gerados pelas imagens de satélite (XIE; SHA; YU, 2008).

### 3.5.2 Fusão de Imagens

Para as imagens utilizadas em sensoriamento remoto, existem inúmeras técnicas que possibilitam melhorar a visualização dos dados gerados pelos diferentes sensores, assim alguns procedimentos de processamento têm sido desenvolvidos, e aplicados para melhorar estas práticas (OLIVEIRA, 2018). A combinação de imagens com melhor resolução espacial, com imagem multiespectral original é um exemplo dessas práticas. A estas operações concede-se o nome de fusão de imagens (NOVO, 2010).

A fusão de imagens consiste na combinação das diferentes características espectrais, e espaciais para sintetizar uma nova imagem com melhor resolução espacial, do que a imagem multiespectral original (BRYN, 2008). No PDI é comum a utilização de imagens pancromáticas de alta resolução espacial, combinadas com imagens de melhor qualidade multiespectrais, e média resolução espacial mediante ao uso de técnicas apropriadas. Desta maneira, podem ser preservadas a resolução espectral, enquanto a resolução espacial é incorporada, permitindo melhorar os detalhes das informações contidas na nova imagem (SCHNEIDER *et al.*, 2003).

Segundo Soares *et al.* (2015), o processo de fusão de imagens de sensoriamento remoto pode ser efetuado tanto com bandas de um mesmo sensor, quanto com as bandas de diferentes sensores. E de acordo com Ejaily *et al.* (2013); Bhaskarrajan (2014), os processos de fusão de imagens pode facilitar a análise e a interpretação de imagens, desde que seja utilizada a técnica correta. Os principais métodos utilizados para fusão de imagens são: Intensidade-Matiz-Saturação (IHS) o mais conhecido (TU *et al.*, 2001); Transformação Wavelet (WAVELET),

Fusão Gram-Schmidt (GRS); Transformação de Brovey (BRO), Componentes Principais (PCA), dentre outros (ADAMI *et al.*, 2007). E esses diferentes métodos de fusão de imagens tem sido testados, e empregados ao longo dos anos para as análises ambientais (SCHNEIDER *et al.*, 2003; ABDIKAN; SANLI, 2012; SOARES *et al.*, 2015).

Recentemente Mhangara *et al.* (2020), avaliaram as diferenças entre 12 métodos de fusão de imagens para o satélite SPOT 5 e 6/7, baseadas em algoritmos Pansharpening. Estes mesmos autores concluíram que as técnicas por Correspondência de Média e Variância Local (IMVM) e Substituição de Componente de Proporção (RCS), apresentaram os melhores resultados em termos de consistência espectral e síntese. Ambos os algoritmos (IMVM e RCS) estão implementados nas ferramentas Orfeo ToolBox (OTB), que é uma biblioteca de código aberto para sensoriamento remoto, que cede seus algoritmos para serem usados por *softwares* de processamento de imagens, a exemplo o *software* QGIS.

O algoritmo Pansharpening IMVM implementado na ferramenta OTB utiliza um filtro LMVM, que aplica uma função de normalização em uma escala local dentro das imagens para igualar os valores de média, e variâncias locais da banda pancromática de alta resolução espacial com aqueles da imagem multiespectral de resolução mais baixa (OTB, 2018; AL-RUBIEY, 2017; MHANGARA *et al.*, 2020). A ocorrência de pequenas diferenças residuais resultantes foram consideradas como sugerido pela banda pancromática de melhor resolução (AL-RUBIEY, 2017; MHANGARA *et al.*, 2020). De acordo com Al-Rubiey (2017), pode ser observado ainda que este método de filtragem melhora a correlação entre a imagem com nitidez total e a imagem multiespectral original. A imagem fusionada baseada no algoritmo Pansharpening IMVM é obtida conforme a Equação 1 (MHANGARA *et al.*, 2020):

$$F_{i,j} = \frac{(H_{i,j} - \bar{H}_{i,j}) s(L)_{i,j(w,h)}}{s(H)_{i,j(w,h)}} E \quad (\text{Eq. 1})$$

em que:  $F_{i,j}$  refere-se às imagens fundidas;  $H_{i,j}$  e  $L_{i,j}$  denota as imagens de alta e baixa resolução espacial, respectivamente, nas coordenadas  $i, j$  do pixel;  $H_{i,j(w,h)}$  e  $L_{i,j(w,h)}$  são os meios locais calculados dentro da janela de tamanho  $(w, h)$ ;  $s$  denota o desvio padrão local;  $E$  é um vetor de erros aleatórios que é considerado estocasticamente independente de  $Z$ .

O algoritmo Pansharpening RCS (Substituição de Componente de Proporção), funde as imagens pancromáticas ortorretificadas (PAN) e as multiespectrais (XS) utilizando um filtro de nitidez de passagem baixa (OTB, 2019; MHANGARA *et al.*, 2020). Conforme mostrado no Guia OTB (2018), a operação de fusão é definida da seguinte forma (Equação 2):

$$\frac{\text{Multiespectral (XS)}}{\text{Filtro (PAN)}} \text{PAN } E \quad (\text{Eq. 2})$$

em que: XS é a imagem multiespectral reprojeta na resolução da imagem pancromática; PAN é a imagem pancromática; E é um vetor de erros aleatórios que é considerado estocasticamente independente de Z.

Os diferentes métodos de fusão de imagens têm sido testados, e empregados para análises ambientais (SCHNEIDER *et al.*, 2003; ABDIKAN; SANLI, 2012; SOARES *et al.*, 2015). Para este trabalho foi utilizada a técnica de fusão RCS, devido a facilidade de ser utilizada, tendo como referência os trabalhos de Ehlersa *et al.* (2010); Amro *et al.* (2014); Chen; Zhang (2017); e Mhangara *et al.* (2020).

### 3.5.3 Segmentação

Segundo Esquef *et al.* (2003), a segmentação de uma imagem, de modo mais simples de entender, seria separar a imagem como um todo nas partes que a constituem, e que se diferenciam entre si. E de acordo com Guimarães e Candeias (2009) Gonzalez e Woods (2010), a segmentação, a grosso modo, seria subdividir a imagem em suas partes, ou objetos constituintes. Das etapas do PDI, a segmentação é considerada a etapa mais crítica para o tratamento da informação, pois nesta etapa serão definidas as regiões de interesse para processamento e análises posteriores. Ressalta-se que quaisquer erros, ou distorções presentes nesta etapa irão refletir nos resultados gerados (ESQUEF *et al.*, 2003).

No processo de segmentação de imagens digitais de sensoriamento remoto, geralmente são utilizados algoritmos baseados em duas das seguintes propriedades básicas de valores de níveis de cinza: a similaridade entre os pixels e a descontinuidade entre eles (GUIMARÃES; CANDEIAS, 2009; GONZALEZ, WOODS, 2010). A técnica de segmentação baseada em similaridade comumente mais utilizada é chamada de binarização. Na técnica de binarização, o nível de cinza é considerado como um limiar de separação entre os pixels que compõem os objetos e o fundo. Nesta técnica, se obtém como saída do sistema uma imagem binária, i.e., com apenas dois níveis de luminância: preto e branco. Essa técnica de segmentação deve ser empregada quando as amplitudes dos níveis de cinza são suficientes para caracterizar os objetos presentes na imagem (ESQUEF *et al.*, 2003).

Já a técnica de segmentação baseada na descontinuidade entre os pixels, consiste em dividir a imagem, considerando as mudanças bruscas nos níveis de cinza entre os pixels

vizinhos. As variações no nível de cinza da imagem, geralmente permitem detectar o grupo de pixels que delimitam os contornos ou bordas dos objetos presentes na imagem. Os métodos utilizados em segmentação baseado em descontinuidade mais empregada são chamados de detecção de bordas (ESQUEF *et al.*, 2003).

Com a evolução das geotecnologias e o surgimento de novos sensores com imagens de alta resolução espacial, as técnicas de classificação e segmentação baseadas em pixel (similaridade e descontinuidade), passaram a apresentar problemas quanto à precisão das análises, devido a maior variação espectral e consequente variabilidade intraclasse (SILVA, 2012). Uma nova abordagem foi desenvolvida, denominada de análise orientada a objetos, ou análise geográfica de imagens baseada em objetos (*Geographic Object Based Image Analysis - GEOBIA*), que tem sido comumente empregada para análise de imagens de alta resolução espacial, principalmente para áreas urbanas (SILVA *et al.*, 2016; BRANCO *et al.* 2018).

A abordagem GEOBIA utiliza algoritmos de segmentação de imagens para criar grupos de pixels (objetos) espectralmente homogêneos, e tratam esses objetos como unidade atômica para análise espacial e classificação de dados de imagem (SHITH, 2010; SILVA, 2012). Nesta abordagem também leva em conta a análise da relação de um objeto com os seus objetos vizinhos, podendo ainda ser criados diferentes níveis de segmentação (SILVA *et al.*, 2016). De acordo com Antunes (2003) e Silva *et al.* (2016), a lógica de orientação a objeto preconiza as características semânticas dos objetos, que podem ser analisadas de acordo com seus aspectos geométricos (topologia, forma e posição) e temáticos (atributos não espaciais), respectivamente.

De acordo com Almeida *et al.* (2014), essa abordagem traz benefícios na construção de mapas temáticos de uso e cobertura da Terra, principalmente para ambientes heterogêneos e complexos como os encontrados em áreas urbanizadas. Segundo esses mesmos autores a utilização desta abordagem para a classificação orientada a objetos teria a vantagem de abordar o espaço de forma mais integrada, identificando contextos mais similares em termos de ocupação do solo. Essa abordagem orientada a objeto é bastante empregada para mapeamento de áreas urbanas utilizando imagens de alta resolução espacial, a exemplo os trabalhos de: Botelho; Centeno (2005); Chagas *et al.* (2009); Luz *et al.* (2009); Genovez (2010); Mendes; Dal Poz (2011); Pedrassolli (2011); Pereira (2011); Piazza e Vibrans (2014); Silva; Araki (2015); Sothe (2015); Rodrigues; Kux (2015); Pereira; Centeno (2017); Ruiz *et al.* (2017).

### 3.5.3.1 Segmentação Multirresolução

Na abordagem da segmentação multirresolução é possível analisar os objetos de uma imagem em diferentes níveis de resolução. De acordo com Leonardi (2010), “ela é fundamentada no fato de que objetos pequenos podem ser mais facilmente analisados em resoluções mais finas, enquanto objetos maiores podem ser adequadamente analisados em uma resolução mais grosseira”. Segundo esse mesmo autor esta abordagem poderá ser realizada utilizando imagens em múltiplas resoluções, pela variação dos parâmetros do algoritmo de segmentação, que altera o nível de resolução do processamento.

O sistema eCognition Developer desenvolvido pela Trimble, utiliza essa abordagem de segmentação multirresolução (*Multiresolution Segmentation*), desenvolvido por Baatz e Schape (2000). Essa técnica utiliza métodos de fusão de regiões onde a similaridade é obtida por meio da minimização dos parâmetros de heterogeneidade interna dos objetos (SILVA, 2012). De acordo com Benz *et al.* (2004), esse algoritmo inicialmente agrupa pixels pela similaridade entre eles, e depois analisa as bordas dos segmentos por meio da descontinuidade dos pixels. Essa abordagem possibilita ao algoritmo agrupar regiões semelhantes, respeitando não apenas o valor radiométrico dos pixels, mas também o contexto (forma, compacidade, textura) em que eles estão inseridos (ESPÍNDOLA, 2006). Usualmente, esse é um dos principais algoritmos de segmentação multirresolução para análise de imagens de sensoriamento remoto (PIAZZA; VIBRANS, 2014; DEFINIENS, 2019).

O algoritmo de segmentação multirresolução proposto por Baatz e Schape baseia-se na natureza fractal das imagens de sensoriamento remoto, e uma técnica de fusão de regiões *pairwise* (BAATZ; SCHÄPE, 1999; 2000; DEFINIENS, 2009). No processo de segmentação, os pares ou regiões de pixels são agrupados em unidades maiores através de interações por meio do algoritmo *Fractal Net Evolution Approach* (FNEA), até que seja encontrados pixels que não satisfazem aos critérios de homogeneidade estabelecidos (ALMEIDA FILHO *et al.*, 1998; DEFINIENS, 2009; BRANCO *et al.*, 2018; DEFINIENS, 2019). Os critérios de homogeneidade são definidos com base na combinação de componentes espaciais (forma) e espectral (cor) dos objetos.

A homogeneidade no sistema eCognition Developer baseia-se em quatro critérios; escala, cor (espectral), suavidade e compacidade (espacial). O fator de escala é o parâmetro principal que determina a heterogeneidade máxima permitida para os objetos da imagem. De acordo com Baatz e Schäpe (2000), este parâmetro tem influência diretamente no tamanho final

dos objetos (segmentos) a serem criados, atribui valores altos ao parâmetro escala, resultam em um número maior de objetos e, com isto, menor será a quantidade de objetos a serem criados. O parâmetro cor está relacionado com a combinação das propriedades espectrais (cor) e da forma dos pixels e/ou dos objetos (FRANCISCO; ALMEIDA, 2012). Já o parâmetro de suavidade está relacionado ao desenho das bordas, e a compacidade tem como máxima expressão a forma de um círculo, ambos os parâmetros contribuem para a definição da forma dos objetos (BRANCO *et al.*, 2018).

Este algoritmo também permite atribuição de peso às camadas de entrada de acordo com o seu grau de importância para o processo de segmentação (SOTHE, 2015). Os valores dos pesos variam entre 0 e 1, sendo que 0 implica na desconsideração do plano de informação no processo de segmentação, e valores maiores, atribui maior grau de importância conferida à respectiva camada (banda) de entrada (BAATZ; SCHÄPE, 2000).

De acordo com Carleer *et al.* (2005), a qualidade da segmentação depende, portanto, não apenas do algoritmo selecionado, mas de um apropriado ajuste dos valores de seus parâmetros (escala, forma/cor e compacidade/suavidade). O ajuste dos parâmetros podem ser feitos de forma de tentativas e erros, não havendo garantia de que os valores ótimos serão determinados, ou ainda, de forma automatizada, em que uma função objetivo é dada por uma métrica para avaliação da segmentação (ACHANCCARAY DIAZ, 2014; SOTHE, 2015).

### **3.5.4 Classificação e Reconhecimento dos Padrões**

A classificação de imagens digitais de sensoriamento remoto, é considerada como uma das etapas finais do PDI. Classificar uma imagem envolve extrair informações, identificar e delimitar objetos e, em seguida, dividi-los em grupos semelhantes/homogêneos com base em seu comportamento espectral (TOLENTINO, 2019). O processo de classificação de imagens geralmente é dividido em dois grupos, sendo eles; supervisionados e não supervisionados.

Na classificação supervisionada são coletadas amostras de treinamento representativas, com identidades conhecidas para classificar pixels com identidades desconhecidas (CAMPBELL; WYNNE, 2011). Basicamente, as características espectrais de cada pixel na imagem são comparadas com as características espectrais das amostras de referência (treinamento), de modo que cada pixel é rotulado como um tipo classe de acordo com as regras de decisão do classificador (LI *et al.*, 2014; TOLENTINO, 2019). Já na classificação não supervisionada, o objetivo do método é agrupar pixels com a mesma resposta

espectral, em várias bandas espectrais, em grupos semelhantes/homogêneos (Clusters), ou em classes que sejam estatisticamente separáveis (NAVULUR, 2006). De acordo com Silva (2012), neste método não há determinação prévia das classes a serem mapeadas, mas sim o número de grupos a serem divididos.

Comparando-se os dois métodos, o processo de classificação supervisionado apresenta algumas vantagens, dentre elas, o analista pode controlar as categorias de interesse, configurar para finalidades e áreas geográficas específicas. Os algoritmos de classificação de imagens digitais, também podem ser categorizados em paramétricos e não paramétricos. Os algoritmos paramétricos baseia-se na suposição de que as classes podem ser modeladas por distribuições de probabilidade e, portanto, podem ser descritas pelos parâmetros dessas distribuições. Por outro lado, os modelos não paramétricos não requerem a natureza paramétrica dos dados, ou seja, os dados não se aproximam do modelo de distribuição da curva normal (RICHARDS; JIA, 2006; TOLENTINO, 2019).

De acordo com Tolentino (2019), os algoritmos não paramétricos são muito promissores para a classificação de imagens digitais. Além disso, esses algoritmos geralmente são baseados em mineração de dados e/ou aprendizagem de máquina, que empregam conceitos de inteligência artificial para tomar decisões baseadas em informações de amostras de treinamento (referência) e generalizá-las para a imagem inteira (LARY *et al.*, 2016; FERNANDES; CHIAVEGATTO FILHO, 2019). O uso desses algoritmos permitem uma maior separação entre as classes, e podem incluir dados não espectrais no processo de classificação.

### 3.6 MINERAÇÃO DE DADOS

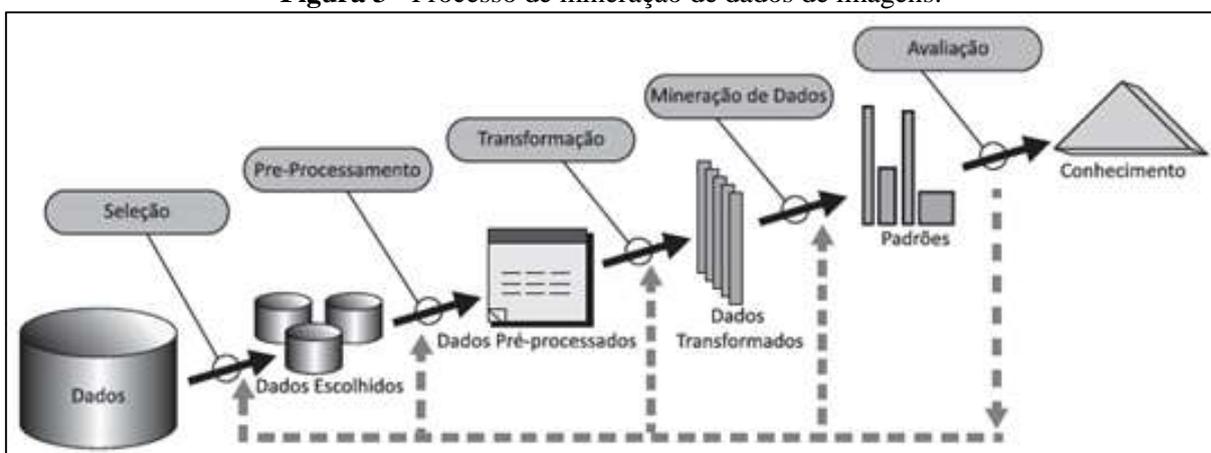
Mineração de Dados (em inglês Data Mining) é uma das fases do processo chamado Descoberta de Conhecimento em Bancos de Dados (DCBD ou KDD, do inglês Knowledge Discovery in Databases) (SANTOS, 2009). O DCBD é entendido como o processo não-trivial de identificação de padrões válidos, novos, potencialmente úteis e compreensíveis, visando melhorar o entendimento de um problema, ou um procedimento de tomada de decisão (FAYYAD *et al.*, 1996). A mineração de dados é a etapa do DCBD responsável pela seleção de técnicas que possibilita o aprendizado prático de padrões a partir de dados, possibilitando

explicações sobre a natureza destes dados e previsões a partir dos padrões encontrados (WITTEN; FRANK, 2005).

O processo de DCBD é interativo, iterativo, cognitivo e exploratório, envolvendo vários passos como: definição do tipo de conhecimento a descobrir, seleção de dados, pré-processamento, transformação, mineração desses dados, subsequente interpretação de padrões e implantação do conhecimento descoberto (SILVA, 2006). Segundo Santos (2009), as etapas do processo DCBD não precisam necessariamente ser seguidos na ordem descrita, por se tratar de um processo iterativo e exploratório, mas alguns de seus passos podem ser executados novamente dependendo do resultado de passos posteriores.

A mineração de dados em imagens digitais utiliza técnicas de DCBD e de outras áreas, respeitando a complexidade e a amplitude semântica deste domínio (SILVA, 2006). Segundo Korting *et al.* (2009), as ferramentas de mineração de dados podem aumentar o potencial da análise e aplicações de dados de sensoriamento remoto. Zhang *et al.* (2002), descreve o processo de mineração de dados em imagens (Figura 3), com a primeira etapa das imagens de um banco de dados, que são recuperadas segundo critérios inerentes à aplicação. Posteriormente, há uma segunda fase de pré-processamento para aumentar a qualidade dos dados, os quais serão submetidos a uma série de transformações (normalização) e de extração de características (atributos), que geram importantes informações a respeito das imagens. E a partir destas informações, a mineração pode ser realizada através de técnicas específicas, com o intuito de descobrir padrões significativos. Os padrões resultantes são então interpretados e avaliados para a obtenção do conhecimento final, que pode ser aplicado no entendimento de problemas, na tomada de decisões ou em outras atividades estratégicas (SILVA, 2006).

**Figura 3** - Processo de mineração de dados de imagens.



Fonte: Fayyad; Piatetsky-Shapiro; Smyth, 1996.

De acordo com Silva (2006), na mineração de dados em imagens digitais existem diferenças importantes em relação a bancos “convencionais”, tais como: a textura, processamento em vários níveis, ambiguidade de interpretação e dependência de domínio. Segundo esse mesmo autor devido a essas diferenças, o processo de mineração de dados em imagens inclui várias etapas, visando obter em cada passo requisitos, e informações que serão fundamentais para a etapa subsequente, respeitando desta forma a contextualização dos dados, a dependência do domínio e superando potenciais ambiguidades das informações.

Em sensoriamento remoto, as técnicas de mineração de dados são empregadas principalmente para classificação de instâncias e/ou padrões. Alguns exemplos de algoritmos de mineração utilizados em estudos ambientais podem ser citados baseados em redes neurais (ANDRADE, 2003; CHAGAS *et al.*, 2009; SILVA, 2012; TOLENTINO, 2019) e em árvore de decisão (LEONARDI, 2010; NONATO; OLIVEIRA, 2013; SOTHE, 2015; BENTO, 2017; RUIZ *et al.*, 2017). Para a presente pesquisa foi adotado o método de Redes Neurais Artificiais (RNA) implementada no *software* WEKA (Waikato Environment for Knowledge Analysis).

### **3.6.1 Redes Neurais Artificiais (RNA)**

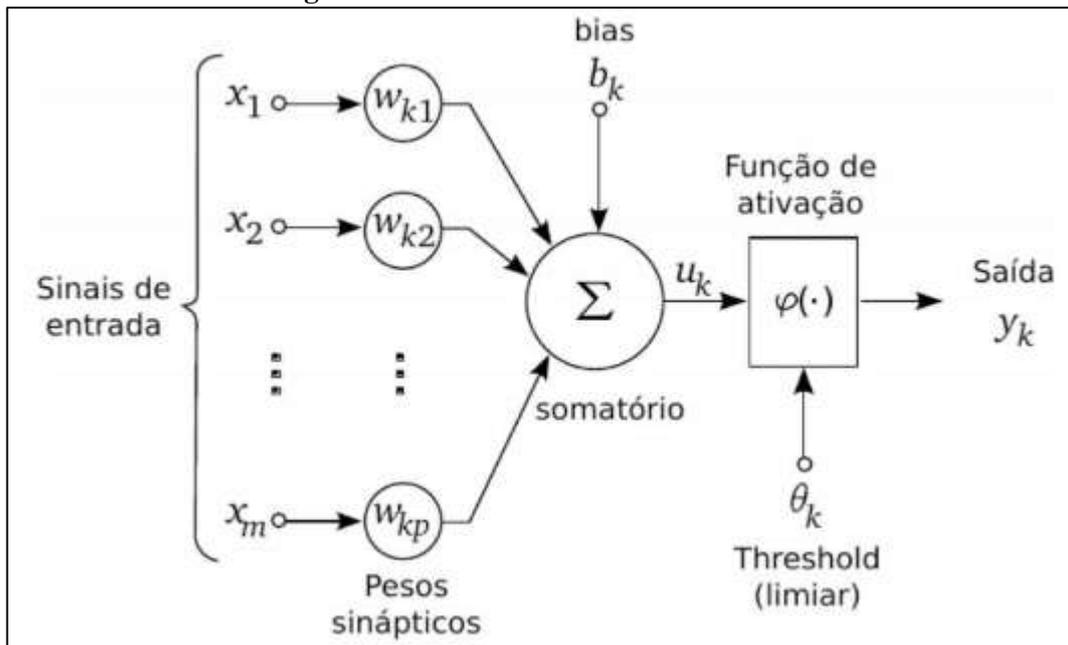
O método de mineração de dados baseado em Redes Neurais Artificiais (RNAs) apresentam um modelo matemático baseado na estrutura neural de organismos inteligentes, e adquirem conhecimento por meio de experiência (NEVES, 2017). De acordo com Haykin (2001), é posteriormente também citado por Silva *et al.* (2012), RNA são sistemas paralelos distribuídos e constituídos de unidades de processamento simples, chamados de "neurônios", que têm capacidade computacional relacionada à aprendizagem e a generalização. Já Castanheira (2008), explica que uma RNA é uma técnica que constrói um modelo matemático, de um sistema neural biológico simplificado, com capacidade de aprendizado, generalização, associação e abstração. Segundo esse mesmo autor assim como no cérebro humano, as redes neurais apresentam uma estrutura altamente paralelizada, composta por processadores simples (neurônios artificiais) conectados entre si.

De acordo com Braga *et al.* (2007), as RNAs são capazes de aprender através de um conjunto reduzido de exemplos (amostras) e depois generalizar o conhecimento adquirido, sendo capaz de dar respostas coerentes para dados desconhecidos, além de serem capazes de extrair informações não apresentadas de forma explícita e possuem grande capacidade de auto-organização. Segundo Haykin (2001), uma característica importante das RNA é a sua

capacidade de aprender a partir do ambiente na qual estão inseridas, ou ambiente de aprendizado, e melhorar seu desempenho através da aprendizagem. Segundo esse mesmo autor uma RNA tenta aprender por experiência, ou seja, diretamente dos dados, através de um processo de repetidas apresentações dos dados à rede.

De acordo com Silva; Almeida; e Yamakami (2012), um modelo básico de RNA (Figura 4) possui os seguintes componentes: um conjunto de sinapses (que são as conexões entre os neurônios da RNA, apresentando cada um deles um peso sináptico); o integrador (que realiza a soma dos sinais de entrada da RNA, ponderados pelos pesos sinápticos); uma função de ativação (que restringe a amplitude do valor de saída de um neurônio); e as bias (que são valores aplicados externamente a cada neurônio que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação e, conseqüentemente, a capacidade de aproximação da rede).

**Figura 4 - Modelo de um neurônio artificial.**

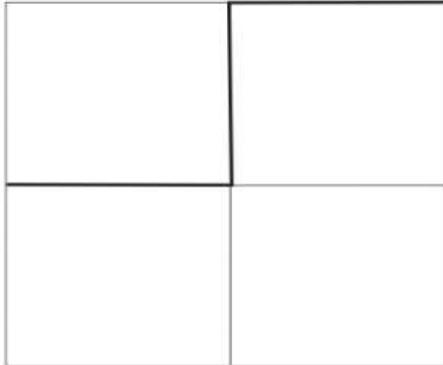


Fonte: Haykin, 2001.

Segundo Barcelos e Toshimitsu (2018) a função de ativação é utilizada para restringir a amplitude da saída de um neurônio. Segundo esses mesmos autores ela também tem uma função restritiva, já que, restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito da rede. Já as bias, tem o efeito de diminuir ou aumentar a entrada líquida da função de ativação, dependendo se este assume valores positivos ou negativos, respectivamente (HAYKIN, 2001; SILVA *et al.*, 2012). Dentre as funções de ativação mais populares, podem ser destacadas as seguintes funções:

- Função Limiar ou Degrau: que normalmente restringe a saída da RNA em valores binários [0,1] ou bipolares [-1,1], sendo representada pela figura 5 e equação 3:

**Figura 5** - Função Limiar.

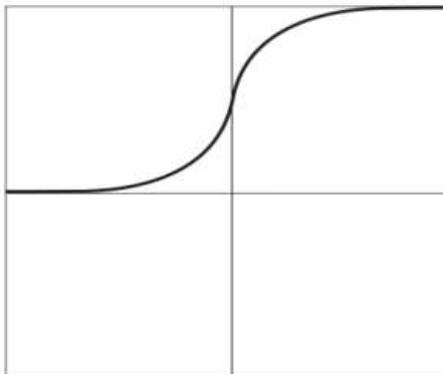


$$\varphi(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (\text{Eq. 3})$$

Fonte: Silva; Almeida; e Yamakami, 2012.

- Função Sigmoidal: É definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1, tendo um formato S. Esse função apresenta uma qualidade muito desejável quando utilizada para classificar os valores para uma classe específica. Logo, pode ser representada pela figura 6 e equação 4:

**Figura 6** - Função Sigmoidal.



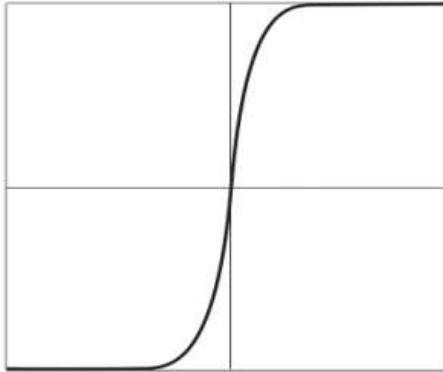
$$\varphi(u) = \frac{1}{1 + \exp(-\alpha u)} \quad (\text{Eq. 4})$$

sendo  $\alpha$  o parâmetro de inclinação da função

Fonte: Silva; Almeida; e Yamakami, 2012.

De acordo com Haykin (2001), a função sigmoide é de longe a mais comum das funções de ativação utilizadas na construção de RNA.

- Função tangente hiperbólica: assume um intervalo de variação de  $-1$  a  $1$ , sendo representada pela figura 7 e equação 5:

**Figura 7** - Função tangente hiperbólica.

$$\varphi(u) = \tanh(u) \quad (\text{Eq. 5})$$

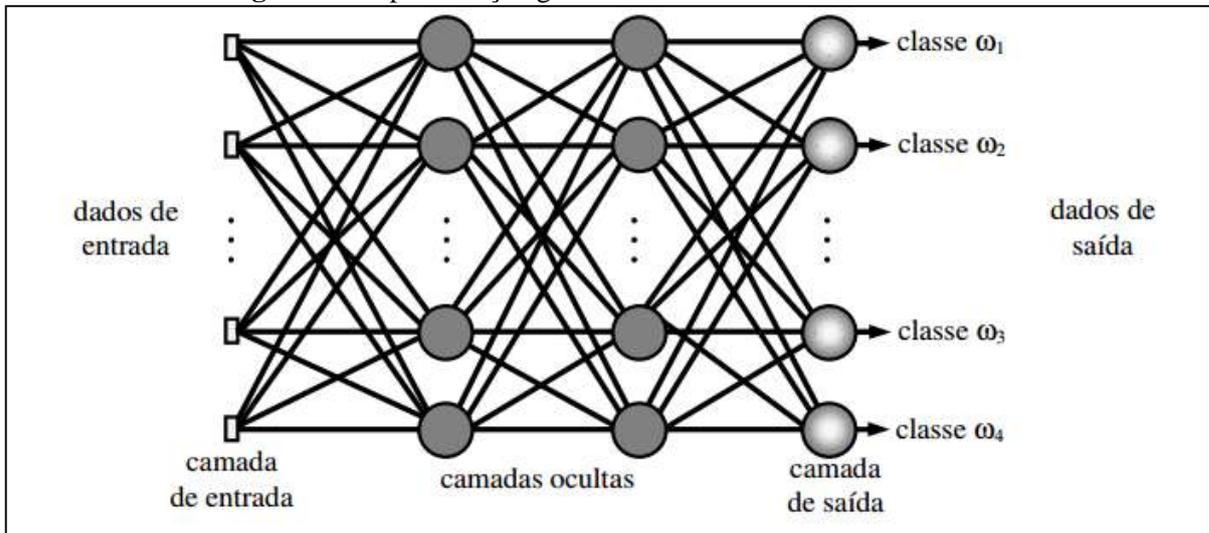
Fonte: Silva; Almeida; Yamakami, 2012.

De acordo com Haykin (2001), a característica da função tangente hiperbólica de assumir valores negativos traz benefícios analíticos.

Outra característica importante de RNA está relacionada à sua arquitetura, que é composta por um grande número de unidades de processamento simples, onde os neurônios são organizados em camadas, conectados por ligações ponderadas de acordo com uma arquitetura especificada, cujo funcionamento é bastante simples (CASTANHEIRA, 2008; PEREIRA, CENTENO, 2017). As camadas são usualmente classificadas em três grupos: camadas de entrada, camadas ocultas (intermediárias ou escondidas) e as camadas de saída. Nas camadas de entrada, os dados são apresentados à rede, não ocorrendo nenhum tipo de processamento, sendo composta pelos atributos de entrada da rede a ser classificada; a camada de entrada se comunica com uma ou mais camadas ocultas (intermediárias), onde ocorre o processamento por meio de um sistema de conexões ponderadas, sendo determinado pelo usuário o número de camadas ocultas; que por sua vez, gera as camadas de saída apresentando o resultado do processamento (GERMAN; GAHEGAN, 1996; BOTELHO; CENTENO, 2005).

Na Figura 8, é apresentada uma tipologia de uma RNA, com os neurônios dispostos nas camadas de entrada, camada oculta e camada de saída. O número de neurônios em cada camada pode ser variável, assim como o número de camadas ocultas (PEREIRA, CENTENO, 2017).

**Figura 8** - Representação gráfica de uma Rede Neural Artificial.



Fonte: Adaptado de Mokhtarzade e Zoj (2007).

Outro aspecto também das RNA está relacionado a suas formas básicas de aprendizado, que utiliza o paradigma do aprendizado supervisionado e/ou aprendizado não-supervisionado. No aprendizado supervisionado é utilizado um agente externo, que indica à rede a resposta desejada para o padrão de entrada, ou seja, é necessário ter um conhecimento prévio do comportamento que se deseja ou se espera da rede. Já no aprendizado não supervisionado (auto-organização), não existe um agente externo indicando a resposta desejada para os padrões de entrada. Neste tipo de aprendizagem, somente os padrões de entrada estão disponíveis para a rede neural. Portanto, a RNA deve procurar algum tipo de correlação ou redundância nos dados de entrada (FERNEDA, 2006; SILVA *et al.*, 2012).

Existem também diversos tipos de RNAs, tais como Perceptron simples, Perceptron de múltiplas camadas (*Multi-Layer Perceptron* – MLP), redes recorrentes, mapas auto-organizáveis de Kohonen, redes de Hopfield, Adaline, entre outras (SILVA *et al.*, 2012). Dentre estas, as RNAs que vêm obtendo maior sucesso na solução de problemas de classificação e reconhecimento de padrões é a MLP treinadas pelo algoritmo Backpropagation (HAYKIN, 2001; BRAGA *et al.*, 2007; PEREIRA, CENTENO, 2017), empregada nesta pesquisa.

### 3.6.1.1 Perceptron de Múltiplas Camadas (Multilayer Perceptron- MPL)

Uma rede neural artificial Perceptron de Múltiplas Camadas (do inglês *Multi-Layer Perceptron* – MLP), é uma RNA do tipo perceptron descrita por McCulloch e Pitts (1943), que possui um conjunto de unidades sensoriais que formam a camada de entrada, uma ou mais

camadas ocultas de neurônios computacionais e uma camada de saída. Esse tipo de rede é totalmente conectada, ou seja, todos os neurônios de qualquer camada estão conectados a todos os neurônios da camada anterior (HAYKIN, 2001; SILVA *et al.*, 2012).

Por padrão, o treinamento de uma MLP é do tipo supervisionado por meio de algoritmo Backpropagation (retropropagação do erro), que tem a função de encontrar as derivadas da função de erro com relação aos pesos e bias da RNA. A função de erro calcula a diferença entre a saída fornecida pela RNA e a saída desejada em relação a um determinado padrão (BISHOP, 1995; SILVA *et al.*, 2012). Segundo Vieira (2000); e Pereira e Centeno (2017), esse algoritmo de aprendizado de RNA é o mais utilizado na classificação de imagem oriundas do sensoriamento remoto.

De acordo com Pal e Mather (2004); e Pereira e Centeno (2017), o Backpropagation é baseado na regra delta proposta por Widrow e Hoff, que consiste em um algoritmo de gradiente descendente, que minimiza o erro entre a saída obtida pela rede, e os resultados fornecidos para o treinamento. O treinamento supervisionado da rede MLP utilizando este algoritmo consiste em dois passos: no primeiro passo, chamada forward, um padrão é apresentado a RNA das unidades da camada de entrada e, a partir desta camada as unidades calculam sua resposta que é produzida na camada de saída, assim o erro é calculado. Já o segundo passo, conhecido como backward, é propagado a partir da camada de saída até o camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados utilizando a regra delta generalizada (SILVA *et al.*, 2012). De acordo com Pal e Mather (2004), para diminuição do erro entre o resultado da rede e o esperado, os pesos vão sendo ajustados conforme a taxa de aprendizado.

De acordo com Bishop (1995), na etapa *forward* os pesos sinápticos são mantidos fixos, ao passo que na etapa *backward* os pesos serão ajustados de acordo com algum método de otimização, sendo que um dos mais populares é o método do gradiente descendente (BRAGA *et al.*, 2007). Segundo esses mesmos autores o ajuste é realizado para que a saída da RNA se aproxime da saída desejada, diminuindo o valor do sinal de erro. O algoritmo Backpropagation pode ser resumido nos seguintes passos:

- 1 - Inicialização: nessa etapa os pesos e o bias da RNA devem ser inicializados. De acordo com Silva *et al.* (2012), uma das formas de realizar esse procedimento é usar aleatoriamente valores de uma distribuição uniforme que esteja no intervalo entre 0 e 1, considerando que a função de ativação a ser utilizada será a função sigmoideal. A escolha desses valores iniciais influencia o comportamento da rede;

- 2 - Ativação (etapa *forward*): são calculados os valores (pesos) dos neurônios da camada oculta e de saída;
- 3 - Treinamento dos pesos (etapa *backward*): calcula-se os erros dos neurônios das camadas de saída e oculta, além da correção dos pesos. Os pesos serão atualizados para ambos os neurônios das camadas de saída e oculta.
- 4 - Iteração: repete os processos a partir do passo 2 até que satisfaça o critério de erro e/ou parada seja satisfeito.

Segundo Haykin (2001); os critérios de paradas mais utilizados para treinamento de redes MLP e outros tipos de RNAs pelo algoritmo Backpropagation são os de minimização do erro, por número de épocas de treinamento ou por validação cruzada. De acordo com Silva (2012), o método de parada de minimização do erro quadrático médio (EQM) consiste em treinar a rede neural até que um valor desejável seja obtido. Já com base no critério de parada pelo número de iterações (épocas) não é muito recomendado por não levar em conta o estado do processo iterativo de treinamento. O critério de parada por validação cruzada permite que o usuário tenha uma avaliação da capacidade de generalização da rede após cada época de treinamento.

### 3.7 UNIDADES DE CONSERVAÇÃO

Devido ao aumento da perda da diversidade biológica que vem ocorrendo em todo o mundo, as discussões acaloradas sobre os temas relacionados à conservação da biodiversidade, vem recebendo um grande destaque nos últimos anos no cenário mundial (BRASIL, 2011a). Com o intuito de minimizar as perdas do patrimônio ambiental natural no planeta, estão sendo firmados vários compromissos pela comunidade internacional nas últimas décadas. Dessa forma, o Brasil ao longo das últimas décadas vem firmando vários desses compromissos, celebrados por meio da sua participação em tratados, convenções e atos internacionais, a fim de proteger os biomas brasileiros, que abriga entre 15 e 20% do número total de espécies do planeta (MMA, 2000).

Entre os vários compromissos internacionais firmados nos últimos anos, a criação das Unidades de Conservação (UC), é considerada como uma das ações mais importantes, e estratégicas para a conservação de ambientes naturais ameaçados (BRASIL, 2011a). Com intuito de assegurar legalmente as UCs em 18 de julho de 2000, por meio da Lei 9.985, o Governo Federal criou o Sistema Nacional de Unidades de Conservação - SNUC. A Lei de

SNUC estabelece mecanismos robustos para assegurar a criação, implantação e gestão de Unidades de Conservação. As Unidades de Conservação consistem no espaço territorial e seus recursos ambientais, incluindo as águas jurisdicionais, com características naturais relevantes, legalmente instituído pelo Poder Público, com objetivos de conservação e limites definidos, sob regime especial de administração, ao qual se aplicam garantias adequadas de proteção.

As UCs devem também assegurar às populações tradicionais o uso sustentável dos seus recursos naturais de forma racional, e proporcionar às comunidades do entorno o desenvolvimento de atividades econômicas sustentáveis, além de estarem sujeitas à normas e regras especiais. Posteriormente, as UCs são legalmente criadas pelos governos federais, estaduais e municipais, após a realização de estudos técnicos dos espaços propostos e, quando necessário, consulta à população (BRASIL, 2011b).

As UCs integrantes do SNUC são divididas em dois grupos, com características específicas: Unidades de Proteção Integral, cujo principal objetivo é preservar a natureza, sendo admitido apenas o uso indireto dos seus recursos naturais, com exceção dos casos previstos em lei; e as Unidades de Uso Sustentável, cujo objetivo principal é compatibilizar a conservação da natureza com o uso sustentável de parcela dos seus recursos naturais (BRASIL, 2011b). As Unidades de Proteção Integral são compostas pelas seguintes categorias: Estações Ecológicas; Reservas Biológicas; Parques Nacionais; Monumentos Naturais; Refúgio de Vidas Silvestres. Já as Unidades de Uso Sustentável são compostas por Áreas de Proteção Ambiental; Áreas de Relevante Interesse Ecológico; Florestas Nacionais; Reservas Extrativistas; Reservas de Fauna; Reservas de Desenvolvimento Sustentável; e Reserva Particular do Patrimônio Natural. A Reserva Biológica de Serra Negra (REBIO Serra Negra) se enquadra nas Unidades de Proteção Integral.

As Reservas Biológicas tem como objetivo a preservação integral da biota, e demais atributos naturais existentes em seus limites, sem interferência humana direta ou modificações ambientais. Entretanto, excetuam-se as medidas de recuperação de seus ecossistemas alterados, as ações de manejo necessárias para recuperar e preservar o equilíbrio natural, a diversidade biológica e os processos ecológicos naturais. Essa área é de posse e domínio público, cujas áreas particulares incluídas em seus limites deverão ser desapropriadas, de acordo com o que dispõe a lei. Além disso, é proibida a visitação pública, exceto aquela com objetivo educacional, de acordo com regulamento específico. A pesquisa científica depende de autorização prévia do órgão responsável pela administração da unidade, e está sujeita às condições e restrições por este estabelecidas, bem como àquelas previstas em regulamento (BRASIL, 2011b).

### **3.7.1 Reserva Biológica de Serra Negra**

A Reserva Biológica de Serra Negra foi criada em 20 de setembro de 1982, pelo Decreto Federal nº. 87.591, situada na região semiárida pernambucana, e abrange os municípios de Inajá, Floresta e Tacaratu. Foi criada com o objetivo de proteger o último Remanescente de Mata de Formação Orográfica (Mata Atlântica em meio à Caatinga), bem como preservar o sertão nordestino, sendo considerado o principal brejo de altitude do nordeste brasileiro, e o único do bioma Caatinga preservado dentro de uma Unidade de Conservação (IBAMA, 1989). Os brejos de altitude de acordo com Araújo Filho *et al.* (2000), são áreas úmidas e isoladas dentro de áreas secas, posicionadas a barlavento com um desnível relativo médio de 200 metros ou mais.

A REBIO de Serra Negra antes de ser decretada como Unidade de Conservação era ocupada por índios (Tribo Kambiwá e Pankararu) que habitavam a região, e utilizavam as terras para práticas agrícolas de subsistência (cultivo de mandioca, abacaxi, entre outros) (BRASIL, 2011a). Mediante a importância dos brejos de altitude presentes na área, em 1950, a área da atual REBIO de Serra Negra foi declarada como Floresta Protetora da União pelo Decreto Federal 28.348 de 7 de junho, mas somente em 20 de setembro de 1982 a área protegida se tornou a primeira Reserva Biológica Federal do Brasil (Decreto 87.591) (BRASIL, 2011a).

A REBIO de Serra Negra ocupa uma área de aproximadamente 624,85 hectares, e está sobre o gerenciamento do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio), sendo a segunda menor da região Nordeste. A Reserva possui valor singular para a conservação da biodiversidade da região, situada em uma área de altitude com espécies vegetais de Mata Atlântica, contornada pelo bioma Caatinga, e é considerada especial quanto à sua formação geoambiental, características fisiográficas, aspectos antropológicos, históricos e culturais de ocupação humana nessa região (FREIRE *et al.*, 2017).

Os municípios que contornam a Reserva possuem baixos indicadores socioeconômicos, e estão inseridos nas microrregiões da Política Nacional de Desenvolvimento Regional (PNDR), nas tipologias Estagnada e Dinâmica de Menor Renda. As cidades no entorno da REBIO apresentam pequeno porte, e acentuada população rural. E devido às baixas condições de promoção do desenvolvimento social desses municípios, e com poucas inserções na economia regional, resultam em baixos indicadores de educação e renda (BRASIL, 2011a).

A REBIO de Serra Negra está totalmente regularizada, inclusive já foi elaborado o seu Plano de manejo. Nessa área não consta oficialmente nenhum conflito fundiário, ou presença de invasores ou posseiros dentro dos limites da Reserva. Contudo, algumas porções da Unidade de Conservação vêm sendo utilizada como áreas de pastejo para animais domésticos (vacas, cabras, cavalos, dentre outros), uma vez que na região os animais são criados soltos e, conseqüentemente, acabam adentrando na Reserva, pois a mesma não está devidamente cercada. Atrelado a isso, outra questão importante relacionada à Reserva é que o entorno da região de REBIO é reivindicada pela população indígena (BRASIL, 2011a).

O Plano de Manejo da Reserva Biológica de Serra Negra, foi iniciado em fevereiro de 2007, e concluído em dezembro de 2010, sendo elaborado com os recursos de Compensação Ambiental resultantes da implantação da Linha de Transmissão 230 kV Recife II/Pau Ferro/Natal, da Companhia Hidro Elétrica do São Francisco (CHESF). Seu conteúdo e processo de elaboração se basearam no “Roteiro Metodológico de Planejamento: Parque Nacional, Reserva Biológica, Estação Ecológica” de Galante *et al.* (2002), que incluía o levantamento biológico em campo, reuniões com comunidades locais e seminários participativos, conforme previsto no roteiro.

De acordo com a SNUC (2000), o plano de manejo é um documento técnico mediante o qual, com fundamento nos objetivos gerais de uma Unidade de Conservação, se estabelece o seu zoneamento, e as normas que devem presidir o uso da área e o manejo dos recursos naturais, inclusive a implantação das estruturas físicas necessárias à gestão da unidade. Segundo o Brasil (2011a), o papel do plano de manejo é ser um instrumento de gerenciamento de Unidades de Conservação, devendo ser elaborado com base na análise dos fatores bióticos, abióticos e antrópicos existentes na unidade e seu entorno, e prevendo ações de manejo a serem implementadas. O Plano de Manejo da Reserva Biológica de Serra Negra pode ser encontrado no site do ICMBio.

### 3.8 ESTADO DA ARTE

O estado da arte é um resumo sobre algumas revisões bibliográficas de trabalhos, que já foram desenvolvidos utilizando metodologias baseadas em mineração de dados, segmentação orientado ao objeto e a utilização de multifontes.

Santos *et al.* (2009), utilizaram dados de imagens de multifontes (RADARSAT-1, JERS-1 e LANDSAT 7 ETM<sup>+</sup>) para o reconhecimento de padrões e feições de uso, e cobertura

do solo na costa do Amapá com o objetivo de subsidiar a análise dos produtos, e processos responsáveis por modificações na costa Amazônica. Sua análise foi realizada aplicando-se dados dos três satélites, e foram digitalmente processados em uma abordagem multisensor, multiescala e multitemporal, correlacionado com dados pretéritos e informações de campo. Os produtos gerados permitiram a análise da área de estudo, e distinguiram oito padrões de uso e cobertura do solo.

Zacchi *et al.* (2010), utilizaram a análise integrada de dados multifonte (sensor Enhanced Thematic Mapper Plus (ETM<sup>+</sup>) e dados aerogeofísicos) para aplicação no mapeamento geológico de formações ferríferas na Serra do Espinhaço Meridional (MG). As técnicas de análises espaciais baseadas em lógica Fuzzy foram utilizadas para a elaboração dos mapas prospectivos convenientes da área de estudo. Assim, esses autores concluíram que a integração dos dados aerogeofísicos e multiespectrais foram satisfatórios, e favoreceram a seleção de alvos com maior potencialidade econômica, restringindo a área de pesquisa, e eliminando falsos positivos para mineração de ferro na região estudada.

Oliveira *et al.* (2011), encontraram resultados satisfatórios a partir do desenvolvimento de um trabalho, que objetivou a detecção de mudanças no uso, e cobertura da Terra ao longo do período de 1988 – 2011. Para tanto, utilizou-se imagens (multifontes) de média resolução espacial do sensor PRISM/ALOS, e imagens do sensor TM/LANDSAT 5 pelo método de pós-classificação para os municípios situados na região Oeste da Bahia (Brasil Central).

Mandanici e Bitelli (2015), objetivaram a detecção de alteração ao longo de quatro épocas diferentes (1987, 1998, 2003 e 2013) na região de ambientes áridos do Oásis de Fayyum (Egito), que estaria sujeito à recuperação ambiental, utilizando imagens da série de satélites LANDSAT - 5 TM, LANDSAT - 7 ETM e LANDSAT - 8 OLI. Tais autores propuseram utilizar na metodologia, a classificação das imagens com base no índice de vegetação (NDVI), realizando o processamento automatizado. Assim, tal metodologia permitiu a classificação automatizada, e os resultados foram satisfatórios, mas estes autores relatam que a metodologia proposta foi projetada para paisagens áridas, e isso poderia limitar suas áreas de aplicação, porém esta solução poderia ser aplicada em outras regiões com características semelhantes.

Pereira e Centeno (2017), avaliaram o tamanho das amostras para o treinamento de redes neurais artificiais (RNA) para classificação supervisionada de imagens multiespectrais, e dados de Laser Scanner. Dessa forma, utilizou-se as imagens multiespectrais de alta resolução espacial, e os dados de um aerolevante altimétricos de uma área densamente urbanizada, realizados através do Laser Scanner. E os autores geraram o RNA especializados na detecção

destes alvos, e os resultados encontrados da classificação utilizando dados espectrais, e altimétricos (acertos globais 97,5%) foram melhores, do que os que apenas utilizaram informações espectrais (acertos globais 87,5%). Além disso, outros autores também utilizaram as técnicas RNA para classificação de superfícies urbanas e rurais, como por exemplo: Botelho e Centeno (2005); Chagas *et al.* (2009); Pereira (2011); Mendes e Dal Poz (2011).

Silva e Araki (2015), desenvolveram uma metodologia para detecção de edificações em ambiente urbano, utilizando imagem GeoEye e dados ALS (*Airborne LiDAR System*), baseada na segmentação de objetos, e submetidos a um processo de classificação baseada em árvores de decisão. A partir da imagem do ALS e do GeoEye, fizeram a ortorretificação das imagens, a qual, junto geraram o modelo digital de superfície normalizada (MDSn), que foi segmentada pela ação do segmentador FLSA (*Full-Lambda Schedule Algorithm*). As amostras representativas para as classes de interesse foram coletadas, e utilizadas para treinar o processo de classificação, com a finalidade de criar regras de decisão. Os resultados foram positivos quando se utilizou o MDS e o MDSn. Ruiz *et al.* (2017), baseando neste método (na segmentação de objetos) obteve resultados não satisfatórios, porém utilizaram imagens com resolução espacial submétrica, adquiridas por Veículo Aéreo Não Tripulado (VANT). Para esse tipo de classificação também foram encontrados outros trabalhos, como; Luz *et al.* (2009); Genovez (2010); Pedrassolli (2011).

Piazza e Vibrans (2014), utilizaram fotografias aéreas de alta resolução espacial (0,39 x 0,39 m) de três bandas no espectro visível (0,38 - 0,70  $\mu\text{m}$ ) para mapear os estágios iniciais de regeneração de florestas secundárias da Floresta Ombrófila Densa no estado de Santa Catarina. Assim, tais autores empregaram os métodos de segmentação multirresolução e classificação por função de pertinência disponibilizada no *software* eCognition®, e obtiveram índices de acuracidade superior a 80%, e concluíram que os resultados foram satisfatório.

Sothe (2015), utilizando métodos de classificação orientada a objetos e técnicas de mineração de dados, para classificar estádios sucessionais de florestas secundárias da Floresta Ombrófila Mista (FOM) em três áreas-teste situadas na região serrana do estado de Santa Catarina, obtiveram resultados satisfatórios. Para este trabalho foram utilizadas ortoimagens do Sistema Aerotransportado de Aquisição e Pós-processamento de Imagens (*Airborne System for Acquisition and Post-processing of Images - SA-API*), obtidas no levantamento aerofotogramétrico de Santa Catarina. Os dados continham três bandas no visível (0,38 - 0,70  $\mu\text{m}$ ), três bandas no infravermelho próximo (0,76 - 0,78  $\mu\text{m}$ ) e o Modelo Digital de Superfície. Os resultados das classificações apresentaram um índice Kappa variando entre 0,6 e 0,89. Essa

mesma autora concluiu que a classificação orientada a objetos foram significativamente superiores à classificação baseada em pixel a pixel.

Dentre os trabalhos encontrados que utilizaram método de classificação por rede neural artificial e/ou pelo processo de segmentação e classificação orientada ao objeto, ressalta-se que não foi encontrado exemplo do uso de imagens multiespectrais do satélite CBERS – 4 MUX/PAN. Essas imagens são consideradas de média resolução espacial (MUX 20 m e PAN 5 m). Quanto os produtos do PE3d (MDE, MDT e Ortoimagens), que são dados de alta resolução espacial, foram elaborados apenas para o estado de Pernambuco, é vem sendo utilizados recentemente em pesquisas. A associação desses produtos, pode ser um diferencial para futuros mapeamento uso e cobertura da Terra no estado de Pernambuco, bem como contribuição para a interpretação e análise da dinâmica espacial.

## 4 METODOLOGIA

A metodologia é apresentada a seguir em diferentes tópicos, a fim de se obter maior clareza e organização dos métodos empregados.

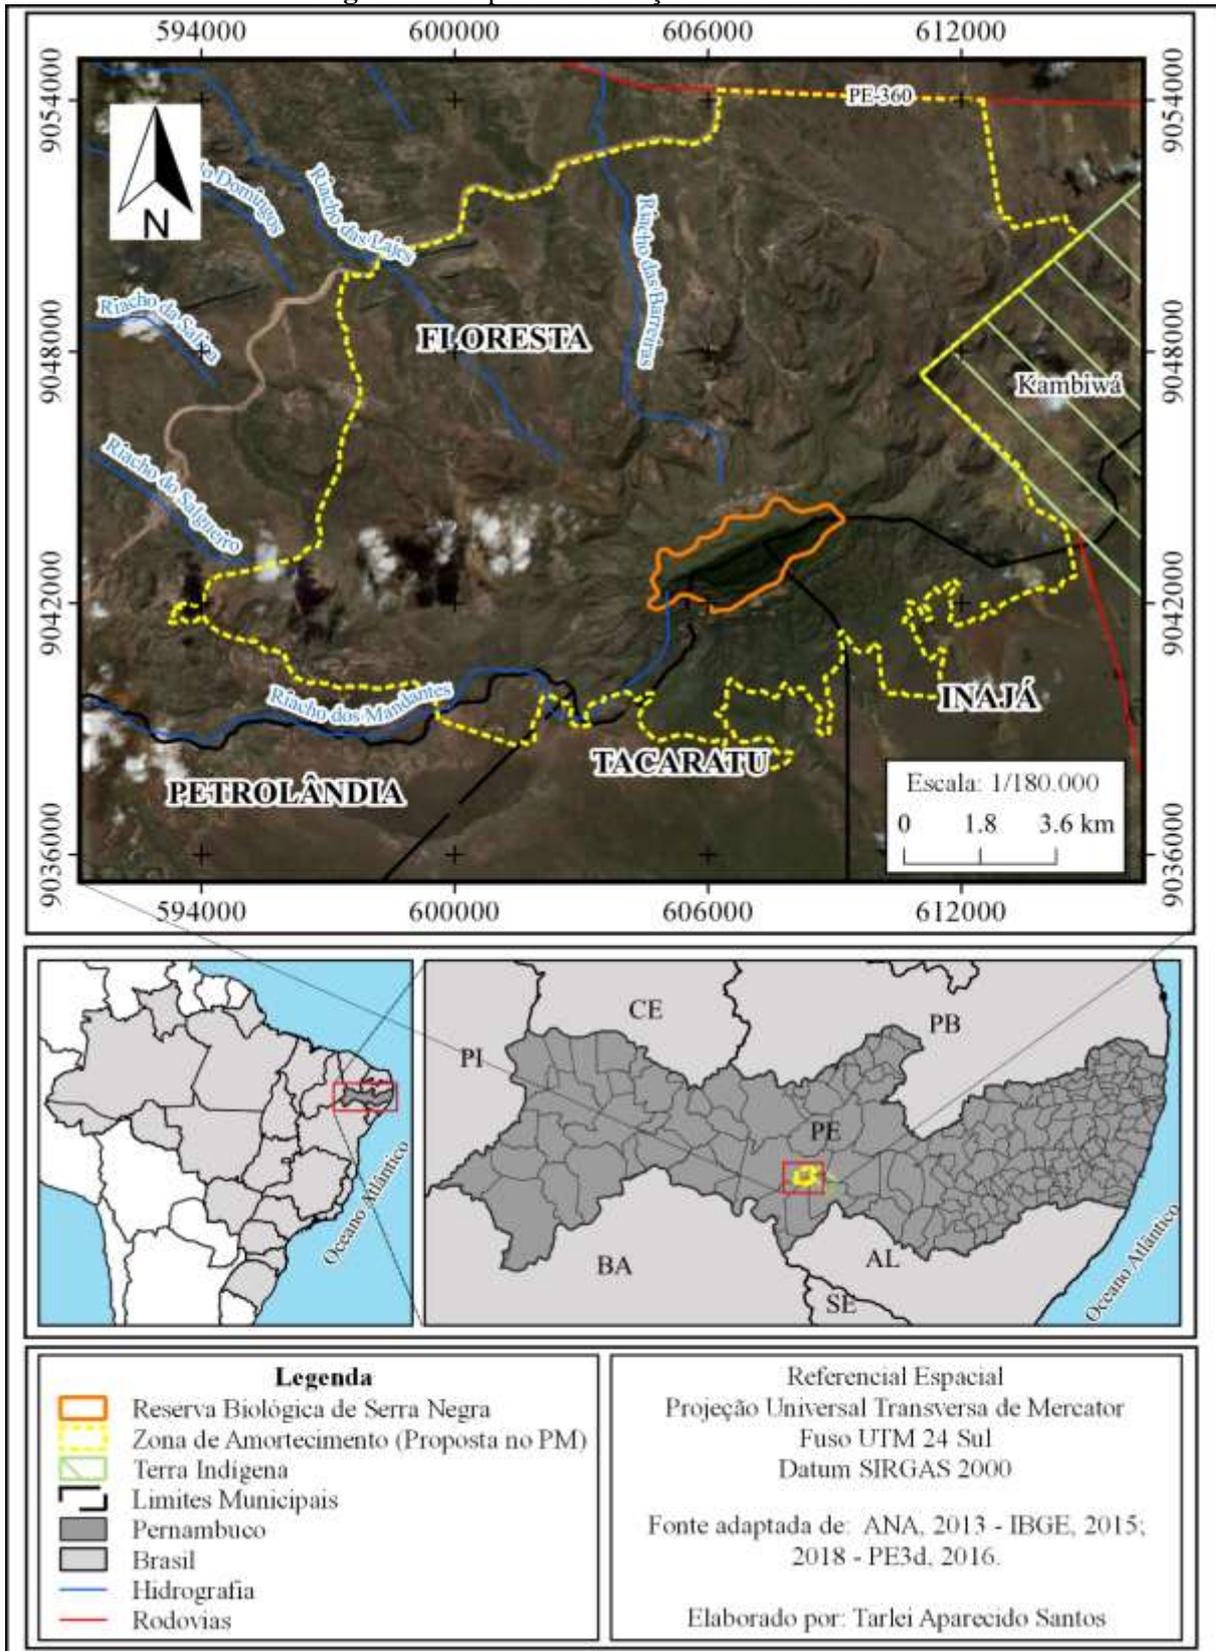
### 4.1 ÁREA DE ESTUDO

A área de estudo compreendeu toda região da Zona de Amortecimento (proposta no plano de manejo) do Remanescente de Mata de Formação Orográfica da Reserva Biológica de Serra Negra (REBIO Serra Negra) e entornos, localizada na mesorregião do Semiárido Pernambucano, na divisa dos municípios de Floresta, Inajá e Tacaratu (entre os paralelos 8°32' e 8°43' de latitude sul, e entre os meridianos 37°56' e 44°10' a oeste de Greenwich) do estado de Pernambuco (Figura 9).

A REBIO Serra Negra foi criada por meio do Decreto Federal nº 87.591 de 20 de setembro de 1982, compreendendo uma área de 624,85 hectares. É a única Unidade de Conservação Federal de floresta serrana no estado de Pernambuco (RODAL; NASCIMENTO, 2002). A Zona de Amortecimento da REBIO de Serra Negra foi proposta no plano de manejo da UC em 2011, mas ainda não foi homologada (ICMBio, 2011). Ela abrange uma área de aproximadamente 21.246 hectares, sendo elaborada a partir do Roteiro Metodológico de Planejamento de Unidades de Proteção Integral: Parque Nacional, Reserva Biológica e Estação Ecológica (GALANTE *et al.*, 2002). Para se obter um maior número amostral para estratificação das fitofisionomias foram considerados as áreas ao entorno da Zona de Amortecimento.

Para a Zona de Amortecimento proposta para REBIO de Serra Negra foi realizada a divisão em cinco zonas internas, sendo elas a Zona Primitiva (ZP), englobando a maior parte da área (54,38%), visando maior proteção e restrições de uso da UC; seguida pela Zona de Recuperação (ZR), que envolve áreas com certo grau de degradação, ocupando 42,01 % da unidade; já a Zona de Uso Extensivo (ZUEx), ocupa cerca 1,67% da área da REBIO, e envolve áreas relativamente íntegras, destinadas as atividades de visitação e manejo; e as Zonas de Uso Especial (ZUEs) (I, II e III) que englobam 1,19 % da UC, destinadas para atividades de manejo e gestão da unidade; e a última Zona de Uso Conflitante (ZUC), que corresponde a menor área, ocupando 0,75% da UC, que são utilizadas por ocasião de rituais indígenas (ICMBio, 2011).

**Figura 9** - Mapa de localização da área de estudo.



Fonte: Adaptado pelo autor (2021), da base cartográfica da ANA, 2013; IBGE, 2015; 2018; PE3d, 2016.

Quanto as características geológicas da REBIO Serra Negra, constitui um maciço residual pertencente à Bacia Sedimentar do Jatobá, situada em terrenos do Cretáceo Inferior das formações Santana e Exú, do grupo Araripe, e fazendo contato ao norte e noroeste com o embasamento Cristalino do Período Pré-Cambriano. A REBIO apresenta ecossistemas variados em função dos diferentes tipos climáticos condicionados pelo gradiente de altitude e pela estratificação geológica, que influenciam diretamente na diferenciação dos ambientes e dos solos. A geologia apresenta variações ao longo da encosta de Serra Negra, representada pelas Formações Marizal (Km), Santana (Ks) e Exu (Ke), todas referentes ao período Cretáceo (ICMBio, 2011).

O relevo da REBIO de Serra Negra é do tipo *cuesta*, com o topo medindo cerca 800 m de largura por 3.000 m de comprimento, orientado no sentido E/NE – O/SO, com altitudes entre 800 e 1.036 m. A escarpa setentrional (N/NO) caracteriza também por apresenta um declive abrupto, ao contrário da escarpa meridional (S/SE) cujo declive é suave, com altitudes variando de 550 a 800 m (ICMBio, 2011). Quanto aos solos da REBIO, devido aos três estratos geológicos que compõem quatro distintos ambientes, diferenciados principalmente pelo gradiente de altitude, foram identificados áreas com: Latossolo Amarelo (típico), Argissolo Vermelho-Amarelo, Luvisolo Crômico, Cambissolo Háptico Eutrófico (de calcário), Cambissolo Háptico Distrófico (de arenito), Planossolo Háptico, Vertissolo Háptico, Neossolo Litólico (de calcário) e Neossolo Quartzarênico (de arenito).

Quanto a hidrologia, a REBIO de Serra Negra encontra-se sobre os domínios da bacia sedimentar do Jatobá, tendo como principais rios o São Francisco e seus afluentes, Moxotó e Pajeú. As principais linhas de drenagem sobre influência da Reserva são dos riachos da Alexandra e do Juazeiro que drenam para o Rio Moxotó, e outros de menor importância que drenam para o Rio Pajeú e Riacho do Navio (FREIRE *et al.*, 2017).

No que se refere ao clima REBIO Serra Negra, assume-se que as características climatológicas da Reserva se assemelham às condições climáticas das regiões do entorno. Assim, ocorrem duas sub-regiões climáticas segundo a classificação de Gaussen, sendo elas:

- Clima de caráter a subdesértico quente, de tendência tropical, com seca de inverno e índice xerotérmico entre 300 e 200, que abrange uma faixa estreita ao longo do vale do Rio São Francisco;
- E do tipo climático mediterrâneo ou nordestino quente, com seca de verão acentuada nas áreas com menores altitudes, média e atenuada em áreas sob influência das serras, e índice xerotérmico varia de 200 a 150.

Em relação a precipitações pluviométricas podem ultrapassar a média dos 1.000 mm por ano nesta região, sendo que o trimestre mais chuvoso vai de março a maio, e o mais seco de agosto a outubro. De acordo com estudos realizados para uma estação climatológica da SUDENE-DRM, a temperatura média anual é de 25,3° C, e o período entre os meses de outubro a dezembro se destacam como o trimestre mais quente da região, e junho a agosto como o mais frio (IBAMA, 1989; LEAL; MELO, 1983; RODAL; NASCIMENTO, 2002; FREIRE *et al.*, 2017).

Quanto a vegetação da REBIO de Serra Negra pode ser encontradas diferentes fisionomias e floras, dependendo da altitude e relevo considerados. De acordo com Freire *et al.* (2017), nas regiões do entorno e do sopé da Serra Negra predomina-se a vegetação xerofítica caducifólia do tipo Caatinga Hiperxerófila Arbustiva e Arbórea, é já nos ambientes de altitudes mais elevadas ocorre a Floresta Estacional Subcaducifólia (Floresta de Altitude), que mantém boa parte de sua folhagem durante o ano todo. E segundo esses mesmos autores entre estas duas formações ocorrem uma área transicional, com uma formação vegetal de caráter xerofítico atenuado, que também perde as folhas nos períodos de estiagens, apresentando, no entanto, porte elevado e maior densidade, caracterizada como Caatinga Hipoxerófila ou Floresta Caducifólia (FREIRE *et al.*, 2017). De acordo com o zoneamento da REBIO de Serra Negra, a vegetação predominante é composta por fisionomias da Caatinga, Cerrado e Mata Ombrófila Densa, além da ocorrência de locais levemente antropizados, considerando toda a Zona de Amortecimento (ICMBio, 2011).

## 4.2 MATERIAL

Os materiais utilizados neste estudo são o Modelo Digital do Terreno (MDT), Modelo Digital de Elevação (MDE) e as Ortoimagens, disponibilizadas pelo Programa Pernambuco Tridimensional (PE3d), através do sítio virtual (<http://www.pe3d.pe.gov.br/mapa.php#>). Foram utilizadas as imagens multiespectrais do satélite CBERS – 4 da Câmera Pancromática e Multiespectral (PAN), e da Câmera Multiespectral Regular (MUX), disponibilizadas pela Divisão de Geração de Imagens (DIDGI), que faz parte da Coordenação-Geral de Observação da Terra (CGOBT) do Instituto Nacional de Pesquisas Espaciais (INPE), através do sítio virtual: (<http://www.dgi.inpe.br/catalogo/>).

Também foram utilizadas a base cartográfica referente aos mapas temáticos dos limites da REBIO de Serra Negra, disponibilizado pelo sistema de Unidades de Conservação do

ICMBio e do Ministério do Meio Ambiente (MMA) (<https://www.icmbio.gov.br/portal/>). Quanto aos limites das Zonas de Amortecimento foram desenhados com base nas coordenadas aproximadas descritas no Plano de Manejo da REBIO de Serra Negra (ICMBio, 2011). Os limites municipais, e estaduais da unidade de federação foram disponibilizados pelo Instituto Brasileiro de Geografia e Estatística – IBGE, na escala 1/250.000, disponível em: <https://www.ibge.gov.br>; e a base hidrográfica disponibilizada pela Agência Nacional de Água (ANA), na escala 1/1.1.000.000, disponível em: <https://metadados.ana.gov.br/>.

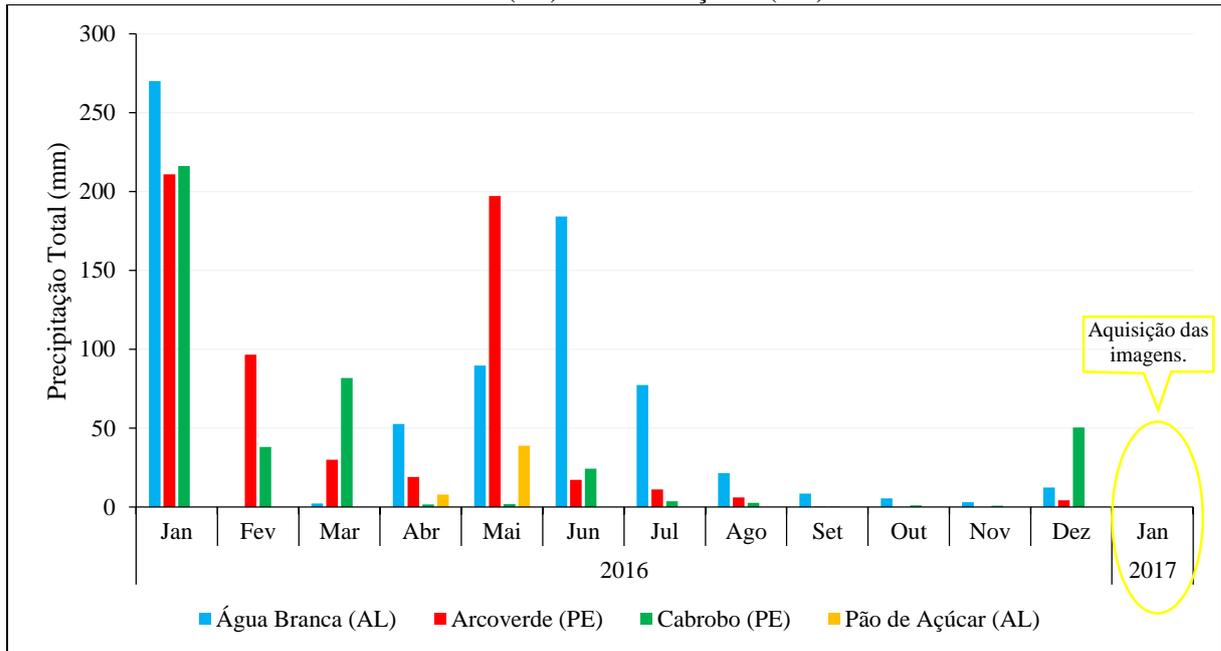
As imagens do MDT representam a altitude do terreno, excluindo as alturas das edificações, ponte, vegetação e quanto às imagens do MDE incluem todas essas elevações. Ambos os modelos possuem 1 metro de resolução espacial, e apresentam um erro máximo altimétrico menor que 25 cm, e atendem ao Padrão de Exatidão Cartográfica (PEC), referente à Classe A nas escalas 1:5.000 e 1:1.000. Foram disponíveis no formato de extensão de arquivo GEOTIFF. Todas as imagens do MDT e MDE estão referenciadas no sistema de coordenadas Universal Transversa de Mercator (UTM), fusos 24 Sul e Datum SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas) (PE3d, 2016). Para compreender toda a área de estudo foram adquiridas 72 cenas para cada um do MDT, MDE e Ortoimagens (totalizando 216 imagens). As cenas compreendem a área entre os paralelos 8°32' e 8°43' de latitude sul, e entre os meridianos 37°56' e 44°10' a oeste de Greenwich.

Para aquisição das imagens multiespectrais, foram adotados como critérios: a ausência de nuvens (0%) sobre a área de estudo; e a disponibilidade para dois períodos distintos, sendo um mais próximo a data de execução do programa PE3d (2014), e outro após um período de 5 anos; e imagens de nível 4 de processamento. As imagens do CBERS – 4, de nível 4 de processamento são imagens ortorretificadas pelo próprio INPE, em que foram aplicadas correções radiométricas e geométricas, além do refinamento utilizando pontos de controle e de um Modelo Numérico de Elevação do Terreno (MNET), obtidos automaticamente de uma base de dados, e/ou selecionados por um operador (COSTA *et al.*, 2007).

Para esta pesquisa foram utilizadas do satélite CBERS – 4 as imagens da câmera PAN, banda 1 (resolução espacial 5 m) e da câmera MUX, as bandas multiespectrais de 5 a 8 (resolução espacial 20 m). As imagens são referentes a orbita/ponto 149/110, sendo o primeiro conjunto de imagens referente ao dia 23 de janeiro de 2017 (ao final do período seco), e um segundo conjunto de imagens referente ao dia 20 de agosto de 2019 (ao final do período chuvoso). Além dos critérios já citados, a aquisição das imagens levou-se em conta as diferenças relevante das respostas espectrais da vegetação ao longo do ano, que são

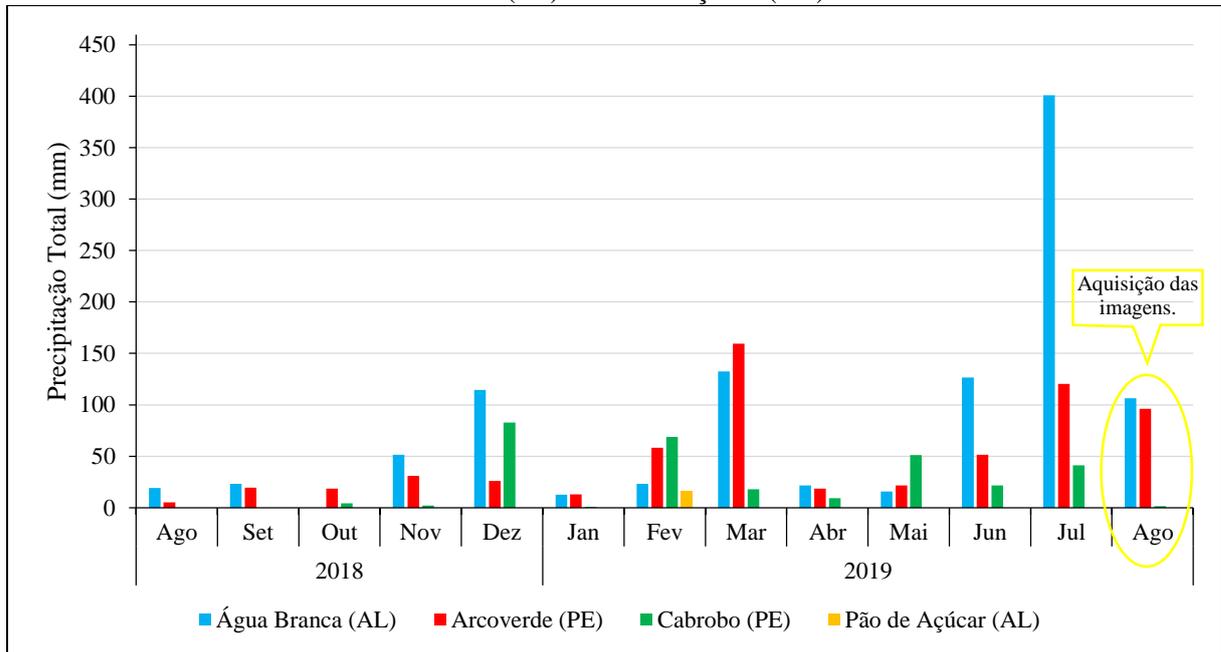
influenciadas pelas condições climáticas. Nos Gráfico 1 e 2 mostra o histórico da precipitação total de 1 ano anterior a obtenção das imagens, das estações convencionais mais próximas da área de estudo situadas nos municípios Água Branca (AL), Arcoverde (PE), Cabrobó (PE) e Pão de Açúcar (AL).

**Gráfico 1** - Histórico da precipitação total mensal (em mm), referente ao período de 01 de janeiro de 2016 a 31 de janeiro de 2019, das estações convencionais de Água Branca (AL), Arcoverde (PE), Cabrobó (PE) e Pão de Açúcar (AL).



Fonte: Adaptado pelo autor (2020), de INMET (2020).

**Gráfico 2** - Histórico da precipitação total mensal (em mm), referente ao período de 01 de janeiro de 2016 a 31 de janeiro de 2019, das estações convencionais de Água Branca (AL), Arcoverde (PE), Cabrobó (PE) e Pão de Açúcar (AL).



Fonte: Adaptado pelo autor (2020), de INMET (2020).

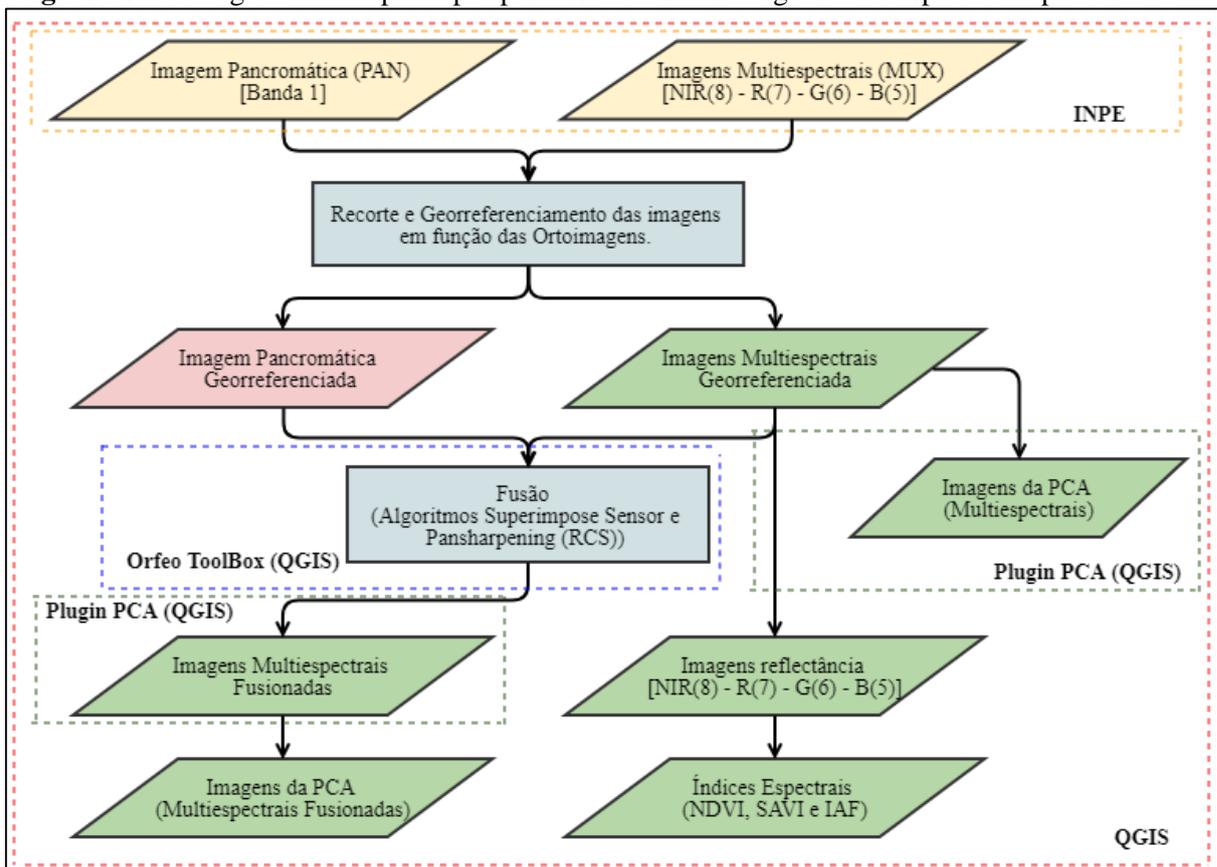
#### 4.3 SOFTWARES UTILIZADOS

- QGIS 2.18.16 - Las Palmas: utilizado para o procedimento de fusão das imagens empregando as ferramentas e algoritmos do Orfeo ToolBox (OTB) e para Análise de Componentes Principais (PCA);
- QGIS 3.10.2-A Coruña: utilizado para registro de imagens, reamostragem dos pixels (MDE e MDT), geração MDA e dos índices espectrais (NDVI, SAVI e IAF), recorte da área de estudo, empilhamento de bandas, seleção dos pontos amostrais de treinamento e validação, edição vetoriais e confecção dos mapas (resultados) finais;
- eCognition Developer 9.2: utilizado para o processo de segmentação multirresolução e extração dos atributos estatísticos e texturais;
- WEKA 3.8.4: utilizado para a mineração de dados visando a geração da Rede Neural pelo algoritmo Multilayer Perceptron;
- Notepad++ 7.8.5: para edição e formatação dos arquivos em formato ARFF e CSV;
- DBF Manager: para edição das tabelas no formato DBF.
- RStudio versão 1.3.1093: utilizado para o teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade.

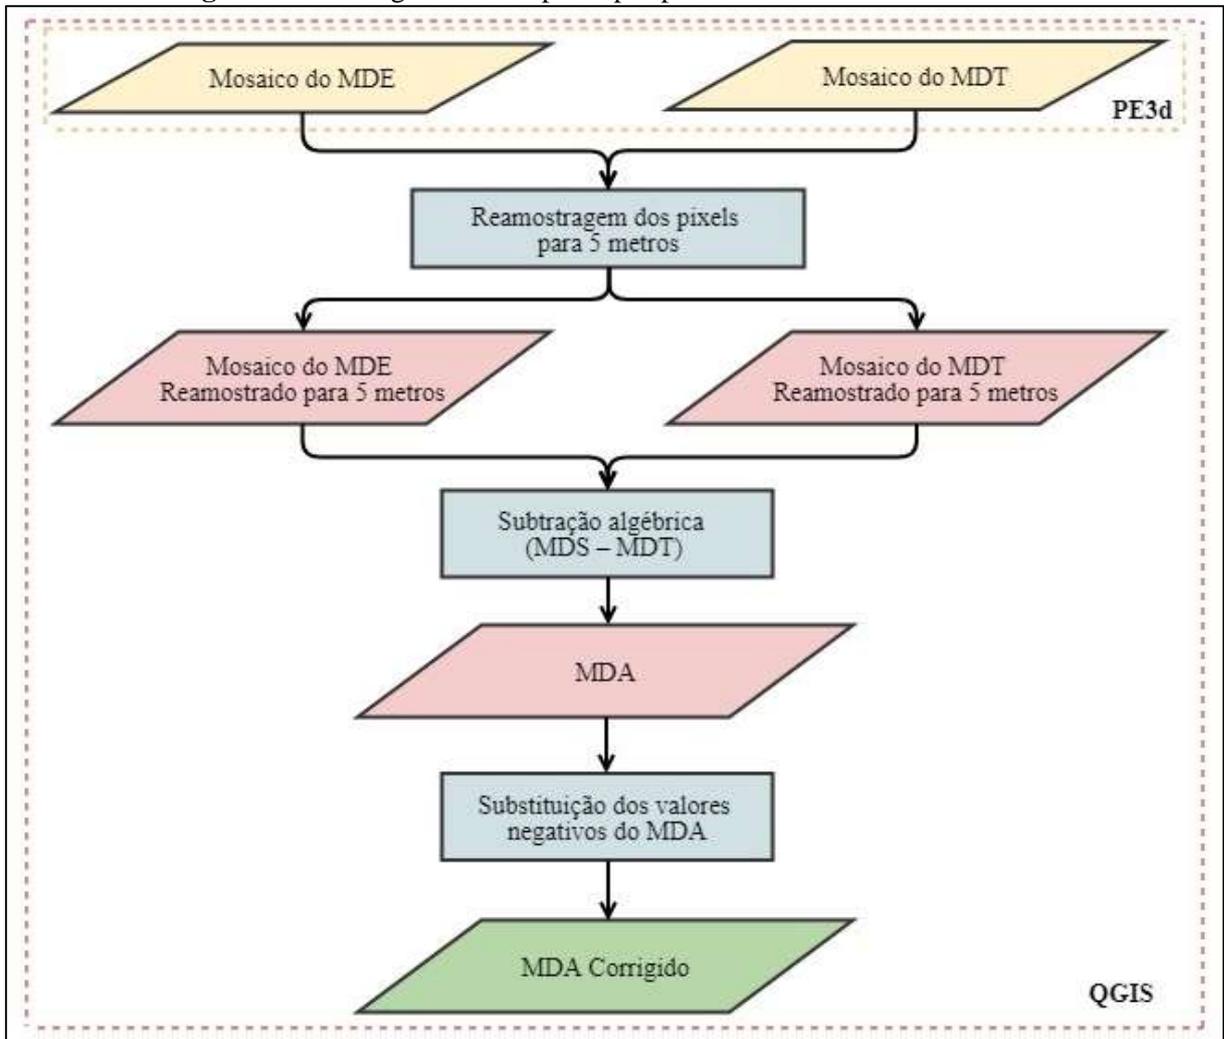
#### 4.4 MÉTODOS

A primeira etapa do procedimento metodológico consistiu na aquisição e seleção dos dados. Posteriormente, na segunda etapa (**Figura 10**) foram realizados o pré-processamento das imagens (recorte, georreferenciamento), geração das imagens de reflectância e dos índices espectrais, além do fusionamento das imagens e a geração das imagens de Principais Componentes (PCA). Nesta etapa também foram realizado o pré-processamento do MDT e MDE para geração do Modelo Digital de Altura (MDA) (**Figura 11**). Na terceira etapa (**Figura 12**) foram realizadas os procedimento de segmentação multirresolução dos planos de informação de entrada e posteriormente a extração dos atributos, e seleção das amostras de treinamento e validação, e preparação dos dados para o processo de mineração de dados. É na última etapa (**Figura 12**), foi aplicado do método de mineração de dados (Redes Neurais Artificiais) para classificação dos segmentos e posteriormente as confecções dos resultados finais e validação.

**Figura 10** - Fluxograma da etapa do pré-processamento das imagens multiespectrais e pancromática.

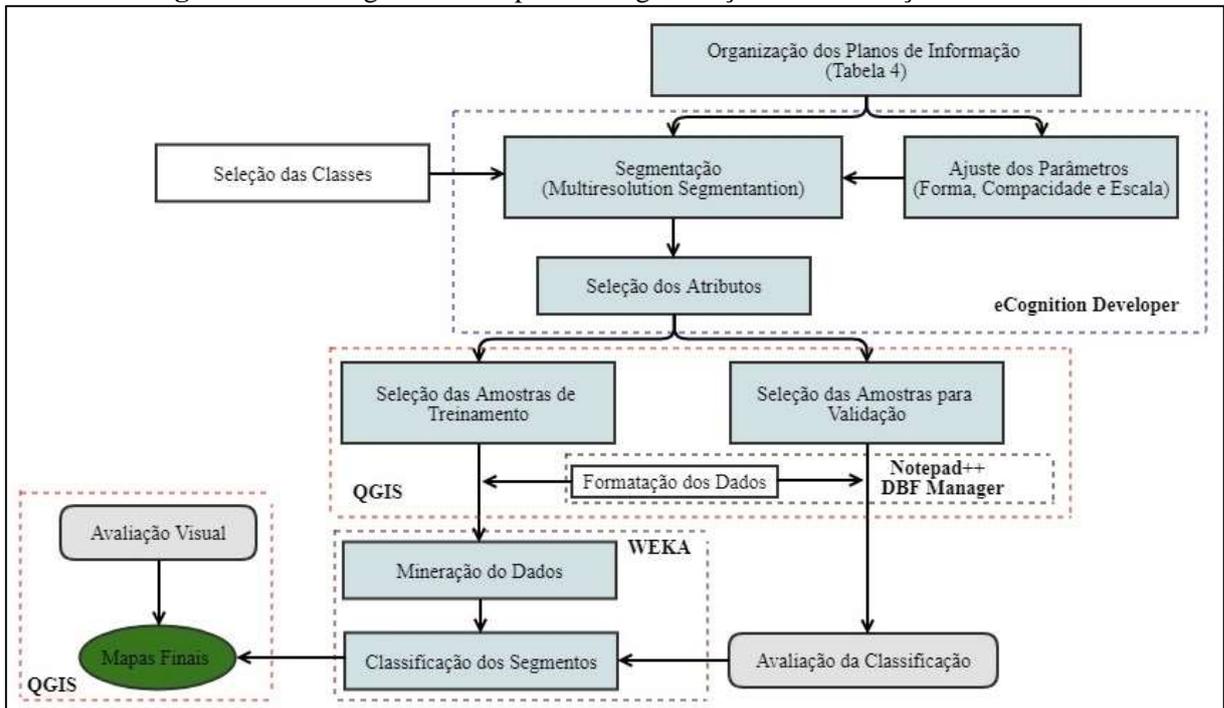


Fonte: Elaborado pelo autor (2021).

**Figura 11** - Fluxograma da etapa do pré-processamento do MDT e MDE.

Fonte: Elaborado pelo autor (2021).

**Figura 12** - Fluxograma da etapa final segmentação e classificação dos dados.



Fonte: Elaborado pelo autor (2021).

#### 4.4.1 Pré-processamento dos dados

Em virtude das diferentes fontes de dados adquiridas (imagens multiespectrais e pancromática do satélite CBERS – 4 MUX/PAN, e o MDT, MDE e as Ortoimagens), o pré-processamento dos dados foram diferentes.

##### 4.4.1.1 Pré-processamento dos dados: MDT, MDE e Ortoimagens

Foram adquiridas 72 cenas (individuais) para o MDT, MDE e as Ortoimagens, com resolução espacial de 1 m, referenciados no sistema de coordenadas planas UTM, Fuso 24 Sul, Datum SIRGAS 2000. O pré-processamento para esta base de dados consistiu em elaborar o mosaico das cenas da área de interesse e o “recorte aproximado” da área de estudo. Posteriormente, o mosaico (cena/imagem) do MDT e MDE foram reamostrados para pixels com resolução espacial 5 m, objetivando reduzir o tempo de processamento nas etapas posteriores.

Por meio da Calculadora Raster do QGIS 3.10.2-A Coruña, efetuou-se a subtração algébrica (MDE – MDT) dos mosaicos reamostrados para 5 m, obtendo-se o Modelo Digital de Altura (MDA). O MDA representa apenas a altura dos objetos acima do terreno, o que simplifica a análise (PEREIRA; CENTENO, 2017). Para área de estudo, o MDA está

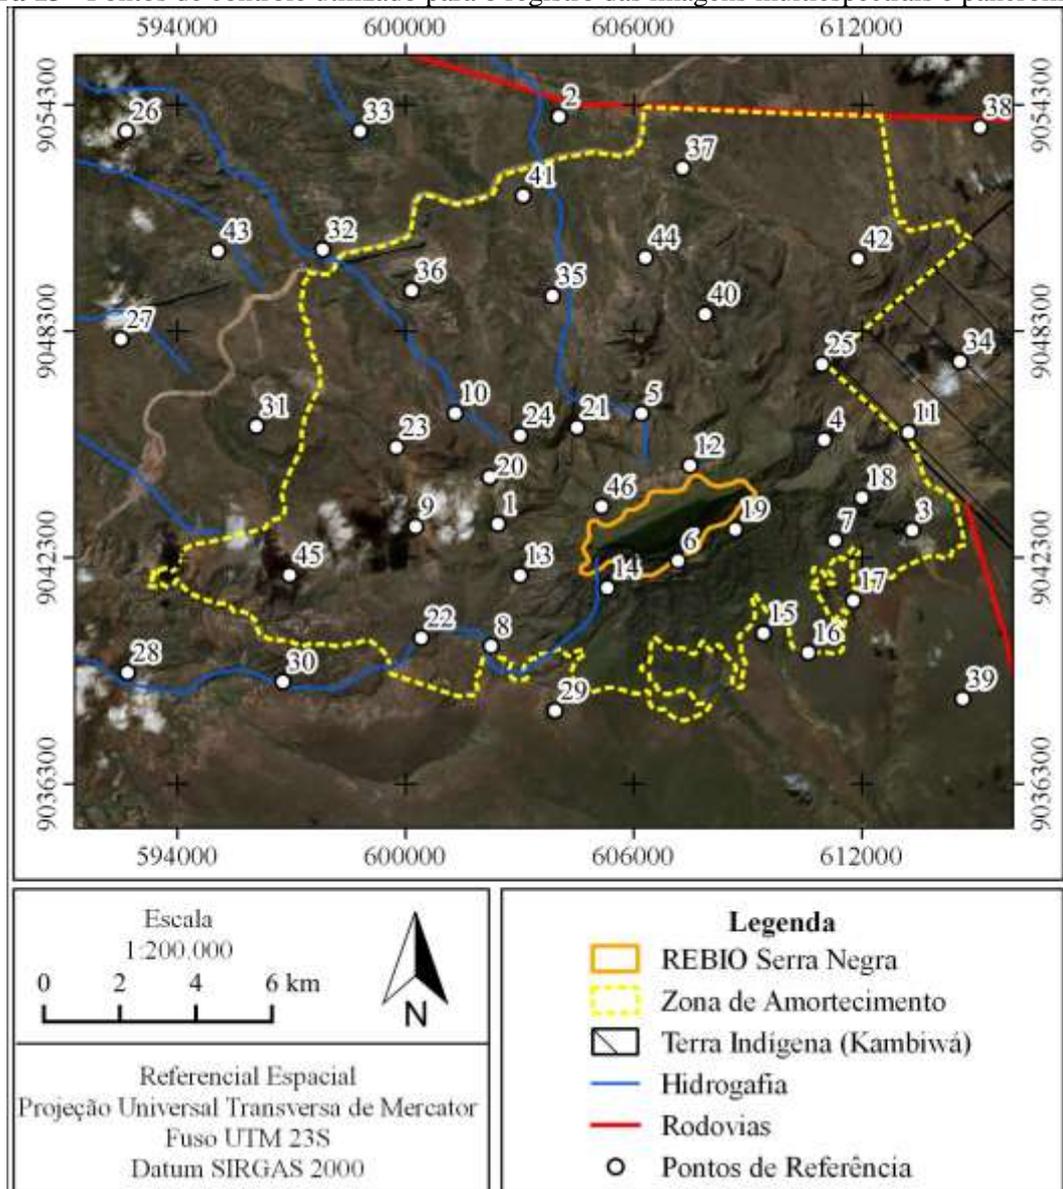
diretamente relacionado a classe de solo exposto e massas d'água, cujo altura é  $< 1$  m; e alturas entre  $1 \text{ m} > 10 \text{ m}$  abrangem as fitofisionomias das áreas de transição, áreas antropizadas e de Caatinga; e objetos acima de 10 m de altura são áreas predominantemente de Floresta de Altitude.

O MDA apresentou alguns valores negativos, ocorridos quando um pixel na posição  $i, j$  apresenta um valor  $Z$  maior para MDT, enquanto que para um pixel na mesma posição  $i, j$  com valor  $Z$  e menor para MDE. Os valores negativos foram substituídos para valor 0,01 m, sendo corrigidos através das ferramentas do *Raster Calculator* do SAGA GIS 2.3.2 implementada no QGIS 3.10.2-A Coruña. Neste procedimento também deveria ser indicado o método de reamostragem dos pixels (interpolação bilinear), e o tipo de dado de saída (Floating 32 bit).

#### 4.4.1.2 Pré-processamento dos dados multiespectrais

Para comparação das imagens tomadas em diferentes períodos, e/ou a partir de diferentes sensores, as mesmas devem ser registradas em um mesmo sistema de coordenadas e co-registrada entre si (ERBEK *et al.* 2004). E segundo Silva (2012), há necessidade da perfeita sobreposição dos dados LIDAR, e imagens multiespectrais para integração correta dos dados. Desse modo, para a perfeita sobreposição dos dados, as imagens multiespectrais da câmera MUX (banda 8 a 5) e PAN (banda 1) do satélite CBERS – 4, foram registradas com base em 46 pontos de controle extraídas a partir de Ortoimagens (**Figura 13**), identificáveis em ambas as imagens. Antes de iniciar o registro das imagens foi feito um “recorte aproximado” da área de estudo. O método de reamostragem utilizado foi o vizinho mais próximo, e o tipo de transformação Polinomial 2º, sendo elas reprojatadas para o sistema de coordenadas planas UTM, Fuso 24 Sul, Datum SIRGAS 2000. Todos os registros foram feitos mantendo-se o erro quadrático médio menor que 1 pixel.

**Figura 13** - Pontos de controle utilizado para o registro das imagens multiespectrais e pancromáticas.



Fonte: Adaptado pelo autor (2021), da base cartográfica da ANA, 2013; IBGE, 2015; 2018; PE3d, 2016.

Para o MDA não houve a necessidade do registro, pois este já se encontrava co-registrado com a Ortoimagens.

#### 4.4.1.2.1 Imagens Reflectância

Para as imagens provenientes do satélite CBERS – 4 câmera MUX, a conversão dos valores em Número Digital (ND) para imagens reflectância monocromática ( $\rho_{\lambda_i}$ ), segue a metodologia adaptada por Pinto *et al.* (2016) e Nascimento *et al.* (2020). O primeiro passo foi transformar os NDs das imagens em valores de radiância monocromática ( $L_{\lambda_i}$ ), conforme a equação 6 proposta por NASA (1998):

$$L_{\lambda i} = \frac{L_{m\acute{a}x} - L_{m\acute{i}n}}{ND_{m\acute{a}x} - ND_{m\acute{i}n}} (ND - ND_{m\acute{i}n}) + L_{m\acute{i}n} \quad (\text{Eq. 6})$$

Adaptando para as imagens do sat elite CBERS - 4 c amera MUX, que possuem resolu  o radiom etrica de 8 bits, o  $ND_{m\acute{i}n}$    igual a 0 e o  $ND_{m\acute{a}x}$  igual a 255, sendo assim, a radi ncia pode ser calculada pela equa  o 7:

$$L_{\lambda i} = \frac{L_{m\acute{a}x\lambda} - L_{m\acute{i}n\lambda}}{ND_{max}} (ND) + L_{m\acute{i}n} \quad (\text{Eq. 7})$$

em que:  $L_{\lambda i}$    a radi ncia monocrom tica de cada banda do sensor ( $\text{Wm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$ );  $ND$    o n mero digital de cada pixel da imagem;  $L_{m\acute{i}n\lambda}$  e  $L_{m\acute{a}x\lambda}$  s o constantes de calibra  o de um determinado sensor (Tabela 2);  $ND_{m\acute{a}x}$  e  $ND_{m\acute{i}n}$  s o os valores m ximos e m nimos que o  $ND$  pode alcan ar.

A reflect ncia monocrom tica corrigida pelo  ngulo solar foi determinada pela equa  o 8 proposta por Allen *et al.* (2002):

$$\rho_{\lambda i} = \frac{\pi L_{\lambda i}}{ESUN\lambda \cdot \text{Cos}(\theta) \cdot d} \quad (\text{Eq. 8})$$

em que:  $\rho_{\lambda i}$    a reflect ncia monocrom tica de cada banda do sensor (adimensional);  $\pi$    uma constante matem tica igual a  $\sim 3,14159$  (adimensional);  $L_{\lambda i}$    a radi ncia monocrom tica de cada banda no sensor ( $\text{Wm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$ ) (Tabela 2);  $d$    o inverso do quadrado da dist ncia relativa Terra-Sol (em unidade astron mica), dada por Iqbal (1983);  $ESUN\lambda$    a irradi ncia solar estratosf rica m dia ( $\text{Wm}^{-2} \mu\text{m}^{-1}$ ) (Tabela 2);  $\text{Cos}(\theta)$    o cosseno do  ngulo zenital Solar no momento da aquisi  o da imagem (em graus) (Tabela 3).

O inverso do quadrado da dist ncia relativa Terra-Sol   dada pela equa  o 9 proposta Iqbal (1983):

$$d = 1 + 0.033 \cdot \text{cos} \left( DSA \frac{2\pi}{365} \right) \quad (\text{Eq. 9})$$

em que:  $d$    o inverso do quadrado da dist ncia relativa Terra-Sol (em unidade astron mica);  $DSA$    o Dia Sequencial do Ano correspondente a data de aquisi  o das imagens (23/01/2017 e 20/08/2019) (Tabela 2).

O  ngulo zenital Solar ( $\theta$ )   obtido por meio da equa  o 10:

$$\theta = 90 - elev \quad (\text{Eq. 10})$$

em que:  $\theta$    o  ngulo zenital Solar (em graus);  $elev$    o  ngulo de eleva  o solar no momento da aquisi  o da imagem (em graus), obtido nos metadados imagem (Tabela 3).

Na tabela 2 mostra a descri  o das bandas do sat elite CBERS-4 MUX, com intervalos do comprimento de onda ( $\Delta\lambda$ ), os coeficientes de calibra  o da radi ncia espectral m nima e m xima ( $L_{m\acute{i}n\lambda}$  e  $L_{m\acute{a}x\lambda}$ ), da irradi ncia solar estratosf rica m dia ( $ESUN\lambda$ ), do sat elite CBERS - 4 c amera MUX.

**Tabela 2** - Descrição das bandas do satélite CBERS - 4 MUX, com intervalos do comprimento de onda ( $\Delta\lambda$ ), os coeficiente de calibração radiância espectral mínima ( $L_{mín\lambda}$ ) e máxima ( $L_{máx\lambda}$ ) e a irradiância solar estratosférica média ( $ESUN\lambda$ ).

Banda MUX	$\Delta\lambda$ ( $\mu\text{m}$ )	$L_{mín\lambda}$ ( $\text{Wm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$ )	$L_{máx\lambda}$ ( $\text{Wm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$ )	$ESUN\lambda$ ( $\text{Wm}^{-2} \mu\text{m}^{-1}$ )
5	0,45 - 0,52	35,3	344,4	1958 $\pm$ 35
6	0,52 - 0,59	25,7	361,8	1852 $\pm$ 29
7	0,63 - 0,69	12,9	352,3	1559 $\pm$ 18
8	0,77 - 0,89	8,9	275,0	1091 $\pm$ 11

Fonte: Pinto *et al.* (2016) e Nascimento *et al.* (2020).

**Tabela 3** - Metadados das imagens usados no projeto da câmera MUX.

Banda MUX	Data de aquisição	DSA	Horário de aquisição (horas)	Órbita/Ponto	Ângulo de elevação solar (graus)
5					62,9628
6	23/01/2017	23	12:56:05	149/110	62,9598
7					62,9568
8					62,9538
5					53,7866
6	20/08/2019	233	12:33:30	149/110	53,7938
7					53,8009
8					53,808

#### 4.4.1.2.2 Índices Espectrais: NDVI, SAVI e IAF

Para geração das imagens dos índices espectrais (NDVI, SAVI e IAF), foram utilizadas as imagens multiespectrais da câmera MUX, as bandas do infravermelho próximo e do vermelho, na resolução espacial de origem de 20 metros.

O NDVI (Índice de Vegetação da Diferença Normalizada) é a razão entre a diferença da imagem reflectância do infravermelho próximo (NIR) e do vermelho (Red) pela soma dessas mesmas bandas, que correspondem as bandas 8 e 7 do satélite CBERS - 4 câmera MUX. Sendo calculada pela equação 11 proposta por Rouse *et al.*, (1974):

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (\text{Eq. 11})$$

em que: NDVI é o Índice de Vegetação da Diferença Normalizada (adimensional);  $\rho_{NIR}$  é a reflectância da banda do infravermelho próximo (adimensional);  $\rho_{RED}$  é a banda do vermelho (adimensional).

Os valores do NDVI variam entre -1 a 1, onde as áreas em que a vegetação é mais densa se aproxima de 1, enquanto as áreas de menor densidade da vegetação se aproxima de -1 (POLONIO, 2015). Esse índice de acordo com Risso *et al.* (2009), Boratto e Gomide (2013), está muito relacionado com a condição e qualidade da vegetação, é sensível à clorofila outros pigmentos que captam a radiação solar.

O Índice de Vegetação Ajustado ao Solo (SAVI), foi um índice desenvolvido na tentativa de minimizar a influência da reflectância do solo sobre o NDVI, incorporando a um fator L (HUETE, 1988). Segundo Almeida *et al.* (2015), de acordo com as características do solo e tipo de cobertura esse fator (L) pode variar entre 0 para vegetações densas e 1 para vegetação mais rala. Para a região estudada o fator L foi igual a 0,5, pois para esta região de interesse a vegetação se encontra em diferentes condições da densidade da cobertura vegetal, e de acordo com Washington-Allen *et al.* (2004), esse valor é empregado na maioria dos casos, independentemente do tipo de solo e cobertura vegetal. A equação 12 do SAVI foi proposta por Huete (1988):

$$SAVI = \frac{(\rho_{NIR} - \rho_{RED})(1 + L)}{(\rho_{NIR} + \rho_{RED} + L)} \quad (\text{Eq. 12})$$

em que: SAVI é o Índice de Vegetação Ajustado ao Solo (adimensional);  $\rho_{NIR}$  é a reflectância da banda do infravermelho próximo (adimensional);  $\rho_{RED}$  é a banda do vermelho (adimensional); L é a constante do fator de ajuste do índice SAVI (adimensional), assumindo-se o valor de 0,5 conforme o recomendado por Washington-Allen *et al.* (2004).

O Índice de Área Foliar (IAF) é a razão entre a área foliar total de uma planta e a área do solo representado pelas plantas, sendo um indicador de biomassa e resistência do dossel (ALLEN; TASUMI; TREZZA, 2002). Sendo estimado de acordo com a equação 13 empírica obtida por Allen; Tasumi; Trezza (2002):

$$IAF = -\frac{\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{0,91} \quad (\text{Eq. 13})$$

em que: IAF é o Índice de Área Foliar (adimensional); SAVI é o Índice de Vegetação Ajustado ao Solo (adimensional).

#### **4.4.2 Fusão das bandas do satélite CBERS – 4 MUX/PAN**

Para o processo de fusão de imagens foram utilizadas as bandas com georreferenciamento corrigidos, da câmera MUX (bandas: 8, 7, 6 e 5) e da câmera Pancromática (banda 1), ambas em número digital (ND). O processo de fusão de imagens visa combinar as

imagens de melhor resolução espacial (imagens pancromáticas) com imagem multiespectral de melhores características espectrais para sintetizar uma nova imagem de melhor resolução espacial e preservando as características espectrais (BRYN, 2008; NOVO, 2010).

Para o processo de fusão das imagens foram utilizados as ferramentas do Orfeo ToolBox (OTB), que é uma biblioteca de código aberto, para sensoriamento remoto que disponibiliza seus algoritmos para serem usados por *softwares* de processamento de imagens, implementada no *software* QGIS 2.18.16. Para utilização das ferramentas do OTB, as bandas multiespectrais (bandas de 5 a 8) foram empilhadas para formar uma única cena (composição colorida 8/7/6/5). Para o processo de fusão das imagens foram aplicados dois algoritmos “*Superimpose Sensor*” e “*Pansharpening (RCS)*” disponíveis nas ferramentas do OTB.

O algoritmo “*Superimpose Sensor*” tem a função de realizar a projeção da imagem multiespectral na geometria das imagens pancromáticas (OTB, 2019). Para utilização desse algoritmo tem-se como entrada a imagem pancromática e as imagens empilhadas multiespectrais, e de um gerenciamento de elevação. A imagem de entrada do gerenciador de elevação pode ser um MDT/DEM ou um modelo do Geóide do local, optando para este projeto a não utilização de nenhum modelo de elevação, visto que as imagens pancromáticas e multiespectrais utilizadas neste processo são de 4º nível de processamento pelo INPE, com correções radiométricas e geométricas baseadas em pontos de controle e em um MNET. O método de reamostragem dos pixels foi do tipo de interpolação bicúbica (bco). Ao final do processamento é gerada uma imagem multiespectral denominada de XS, reprojeta na geometria da resolução espacial da imagem pancromática.

Posteriormente, utiliza-se os algoritmos “*Pansharpening*” baseando-se no método de Substituição de Componente de Proporção (RCS), que tem a função de fundir a imagens pancromáticas ortorretificadas (PAN) e as multiespectrais (XS) usando um filtro de nitidez de passagem baixa (OTB, 2019; MHANGARA *et al.*, 2020). Ao final do processamento é gerada uma imagem multiespectral (composição de entrada 8/7/6/5), com a resolução espacial final de 5 metros, mantendo se próximo os valores do número digital da imagem original de entrada. Para esse procedimento não foi realizada avaliações quanto a perda da consistência radiométrica.

#### **4.4.3 Geração das imagens de Análise por Principais Componentes (PCA)**

A Análise por Principais Componentes (PCA), também chamada de Transformação por Principais Componentes ou Transformação de Karhunen-Loeve, segundo Crósta (1992), é uma das funções do processamento digital de imagens mais poderosas na manipulação de dados multiespectrais. A principal função PCA é determinar a extensão de correlação existente entre duas ou mais bandas através de uma transformação matemática, removê-la, a fim de diminuir o volume de dados armazenados (CRÓSTA, 1993; UCHOA; CASTRO, 2011).

De acordo com Crósta (1993), a principal tarefa executada pela PCA pode ser resumida da seguinte forma: dados um conjunto de imagens *M*, serão analisadas as correlações entre elas, onde será produzido um novo conjunto *M* de imagens novas, com nenhuma correlação entre si. De modo geral, o novo conjunto *M* de novas imagens apresentarão as seguintes características: sendo a primeira delas, denominada de 1 a Principal Componente (PC), que irá conter a informação que é comum em todas as bandas de entrada; e a 2a PC irá conter a feição espectral mais significativa do conjunto, e assim sucessivamente as PCs de ordem superior irão conter feições espectrais cada vez menos significantes até a última PC, que concentrará então a informação que sobrar.

As imagens da PCA foram geradas apenas para as bandas (5, 6, 7 e 8) multiespectrais da câmera MUX/CBERS – 4, para os dois anos de aquisição das imagens. Primeiramente, as imagens em número digital foram empilhadas, e posteriormente através do Plugin PCA implementado no *software* QGIS 2.18.16, foram geradas as imagens das PCA. O procedimento foi realizado para ambas as imagens georreferenciadas na resolução espacial original (20 m) e para as imagens fusionadas (resolução espacial 5 m), com objetivo de determinar a extensão de correlação existente entre bandas multiespectrais.

#### **4.4.4 Planos informação (camadas de entrada)**

Foram organizadas em diferentes planos informação, as camadas (imagens) de entrada, que posteriormente seriam utilizadas no processamento de segmentação multirresolução. O intuito dessa organização foi elaborar diferentes combinações entre as camadas para verificar a influência delas na geração dos segmentos e classificação. Os planos de informação são compostas pelas bandas multiespectrais em número digital, imagens das PC e dos índices espectrais (NDVI, SAVI e IAF) e MDA, foram organizadas da seguinte forma (Tabela 4):

**Tabela 4** - Organização dos planos informação.

<b>Entrada</b>	<b>Planos de informação (banda)</b>	<b>Nº de Camadas</b>
I	NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8
II	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11
III	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9
IV	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12
IMFSV	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8
IMFSVI	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11
IMFSVII	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9
IMFSVIII	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12

NIR – canal do infravermelho-próximo; R (Red) – canal vermelho; G (Green) – canal verde; B (Blue) – canal azul; APC - Análise por Principais Componentes; NDVI - Índice de Vegetação da Diferença Normalizada; SAVI - Índice de Vegetação Ajustado ao Solo; IAF - Índice de Área Foliar; MDA - Modelo Digital de Altura. \*IMFS são as imagens fusionadas (R/G/B/NIR).

\*IMFS- Imagens fusionadas.

#### 4.4.5 Segmentação dos planos de informação

Para o processo de segmentação foi utilizado o algoritmo *Multiresolution Segmentation*, desenvolvido por Baatz e Schape (2000), disponível no *software* eCognition Developer 9.2, disponibilizado pelo laboratório ESPAÇO de Sensoriamento Remoto e Estudos Ambientais, do Departamento de Geografia da UFRJ. Esse *software* permite criação de objetos (segmentos) com base, tanto no valor do pixel (reflectância e/ou no número digital) como na forma do objeto, podendo também ser implementadas outras camadas temáticas, tais como o MDA, NDVI, SAVI e IAF.

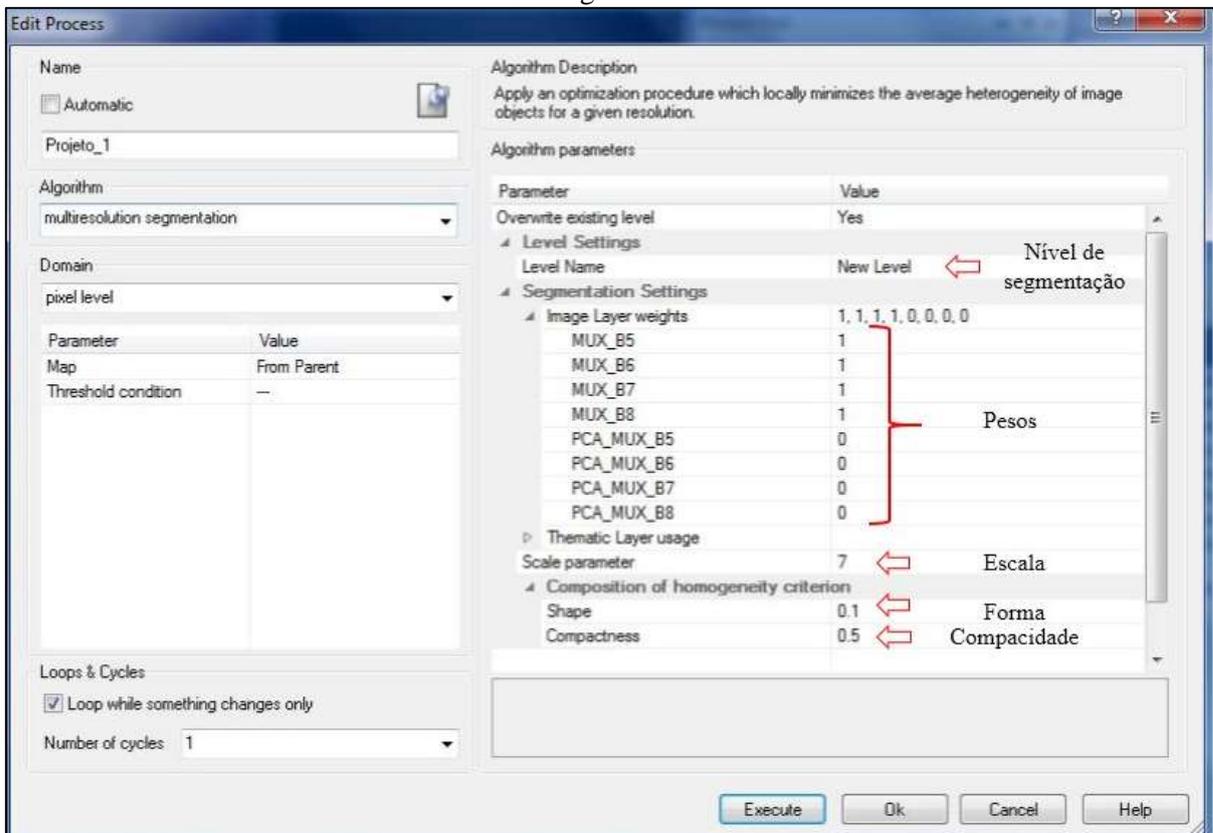
Este segmentador permite a extração de objetos (segmentos) homogêneos utilizando as imagens em diferentes escalas (resoluções espaciais). O princípio da segmentação multirresolução baseada neste algoritmo inicia-se por um processo, que a partir de um “pixel-mente” vai agrupando vizinhos mais próximos que satisfazem a um critério de similaridade ou homogeneidade estabelecido (BRANCO *et al.*, 2018). O agrupamento dos pixels continuará em crescimento até que seja encontrados pixels que não satisfazem a esses critérios (ALMEIDA FILHO *et al.*, 1998).

A atribuição de peso as camadas de entrada deve ocorrer de acordo o seu grau de importância para o processo de segmentação (SOTHE, 2015). Os valores dos pesos variam entre 0 e 1, sendo que 0 implica a desconsideração do plano de informação no processo de

segmentação, e valores maiores, atribui maior grau de importância conferida à respectiva camada (banda) de entrada (BAATZ; SCHÄPE, 2000).

Na Figura 14, mostra a janela do *software* eCognition Developer 9.2, para configuração dos critérios da homogeneidade. Sendo que para este programa são estabelecidos os parâmetros de forma (*Shape*) e de compacidade (*Compactness*) e escala. O campo de forma modifica a relação entre os critérios de forma e cor (cor = 1 - forma). O campo de compacidade age da mesma maneira como critério suavidade (suavidade = 1 - compacidade) (SILVA, 2012).

**Figura 14** - Janela do *software* eCognition Developer 9.2 para configuração dos critérios da homogeneidade.



Fonte: Elaborado pelo autor (2021).

Foram elaborados diferentes projetos no *software* eCognition Developer 9.2, e todos os parâmetros de segmentação foram ajustados individualmente para cada plano de informação. Foi definido apenas um nível de segmentação, e o ajuste dos parâmetros de segmentação baseou-se nos estudos desenvolvidos por Castro *et al.* (2017); Francisco; Almeida (2012); e Branco *et al.* (2018), onde diferentes parâmetros de segmentação foram testados. Para cada novo plano de informação, novos testes foram realizados, analisados visualmente, tendo como critério a comparação da forma e tamanho dos objetos (segmentos) formados, bem como sua

representatividade, relacionando com as classes da legenda identificadas conforme Silva (2012) e Branco *et al.* (2018) recomenda.

De acordo com Francisco; Almeida (2012), o parâmetro de cor tende a ser mais importante na segmentação do que a forma. Por isso, em todas as segmentações realizadas foram atribuídos para o parâmetro forma o valor 0,1 e, conseqüentemente, a cor assumiu o fator 0,9. Já para os parâmetros da compacidade atribuiu-se o valor 0,5 para todas as segmentações realizadas, e assim, o fator suavidade assumiu o mesmo valor, visto que é complementar de 1. Para os parâmetros de escala foram testados diferentes valores, variando entre 5 a 40, sendo ajustados individualmente para cada camada de entrada (Tabela 5). Assim, atribuiu um peso as bandas para cada camada de entrada (Tabela 5), que melhor contribuía para diferenciação das classes, sendo ele condicionado a:

- Maior peso sempre para os plano de informação do MDA, NDVI e SAVI;
- Entradas de apenas as bandas multiespectrais peso igual para todas as camadas;
- Entradas das bandas multiespectrais e do NDVI, SAVI e IAF, maior peso (1,0) para os índices espectrais do NDVI e SAVI, seguido por um peso intermediário (0,8) para as bandas (8 e 7) que os compõe, e menor peso (0,5) para as demais camadas (bandas 5 e 6, e do IAF);
- Entradas das bandas multiespectrais e do MDA, peso intermediário (0,8) igual para todas as bandas multiespectrais e o maior peso ao MDA;
- Entradas das bandas multiespectrais e dos índices espectrais, e o MDA, atribui-se maior peso para MDA, NDVI e SAVI; seguido por um peso intermediário (0,8) para as bandas (8 e 7) que os compõe, e menor peso (0,5) para as demais camadas (bandas 5 e 6, e do IAF);
- Repetiu está lógica para as imagens fusionadas.

Para as imagens PCA não foram atribuídos pesos a elas no processo de segmentação, sendo extraído apenas os atributos das componentes para análise no processo de mineração de dados, com isso o principal foco da PCA foi remover redundância nos dados multiespectrais. Na tabela 5 mostra o ajuste final de todo parâmetro de segmentação.

**Tabela 5** - Parâmetros finais de segmentação multirresolução.

	Planos de informação (banda)	Nº de Camadas	Escala	Forma	Compacidade	Pesos								**Projeto
						B	G	R	NIR	NDVI	SAVI	IAF	MDA	
23/01/2017	NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8	8	0.1	0.5	1	1	1	1	-	-	-	-	1
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11	7	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	-	2
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9	30	0.1	0.5	0.8	0.8	0.8	0.8	-	-	-	1	3
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12	27	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	1	
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8	36	0.1	0.5	1	1	1	1	-	-	-	-	5
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11	28	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	-	6
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9	32	0.1	0.5	0.8	0.8	0.8	0.8	-	-	-	1	7
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12	27	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	1	8
20/08/2019	NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8	7	0.1	0.5	1	1	1	1	-	-	-	-	9
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11	7	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	-	10
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9	27	0.1	0.5	0.8	0.8	0.8	0.8	-	-	-	1	11
	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12	22	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	1	12
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	8	30	0.1	0.5	1	1	1	1	-	-	-	-	13
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	11	24	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	-	14
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	9	27	0.1	0.5	0.8	0.8	0.8	0.8	-	-	-	1	15
	*IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	12	23	0.1	0.5	0.5	0.5	0.8	0.8	1	1	0.5	1	16

\*IMFS - Imagens fusionadas

\*\*Projeto – Ordem das pastas criadas para cada plano de informação.

Fonte: Elaborado pelo autor (2021).

Após gerar os resultados que atendiam aos propósitos do estudo, os objetos (segmentos) e os  $n$  atributos pertencentes a cada um deles, os dados foram exportados para o formato vetorial shapefile (.shp), para uso posterior na seleção das amostras para treinamento e classificação dos dados.

#### **4.4.6 Seleção dos atributos**

O *software* eCognition Developer 9.2 dispõe de dezenas de atributos estatísticos, geométricos e texturais para a descrição de classe, além da opção da geração de um número indeterminado de atributos customizados pelo usuário (NOVACK, 2009; BRANCO *et al.*, 2018). Diante das inúmeras possibilidades para seleção dos atributos, conforme recomendado por Sothe (2015), foram priorizados os atributos estatísticos e texturais, ao invés dos geométricos, por se tratar predominantemente de áreas naturais, em que os extratos (objetos) possuem formas irregulares.

Os atributos texturais são baseados no método proposto por Haralick *et al.* (1973), *Grey Level Co-Occurrence Matrix* (GLCM), que consiste nos cálculos das métricas texturais a partir de matrizes de co-ocorrência do valor digital, com base na relação espacial existente entre os valores digitais em diferentes direções (BRANCO *et al.*, 2018).

Para as bandas multiespectrais em número digital (ND) foram utilizados os atributos estatísticos relacionados: ao brilho (que representa o brilho total de um objeto na imagem); a média (dos valores ND); desvio padrão (que representa o grau de dispersão dos ND em torno da média); e a máxima diferença (que é a maior diferença entre a intensidade média encontrada dentro de uma região para uma banda da imagem fornecida). Quanto aos atributos texturais foram utilizados os relacionados a entropia (GLCM) e de homogeneidade (GLCM) em todas as direções para referidas bandas. Para as imagens dos índices espectrais (NDVI, SAVI e IAF), MDA e PCA foram extraídos apenas os atributos relacionados a média do valores dos pixels por segmento.

O atributo de entropia (GLCM), consiste na medida estatística da aleatoriedade dos dados da imagem, que utiliza as frequências de co-ocorrências de níveis de cinza em vez de usar frequências de valor de ponto. A homogeneidade (GLCM), retorna um valor que representa a distância entre a distribuição dos elementos em relação à diagonal da matriz de co-ocorrência dos tons de cinza. A faixa dos valores retornados está entre 0 e 1, sendo que para imagens com valores baixos, a variação do valor retornado será próximo a zero (HARALICK *et al.*, 1973).

O número de atributos utilizados por plano de informação encontra-se apresentado na tabela 6 a seguir.

**Tabela 6** - Número de atributos por plano de informação.

Entrada	Planos de informação (banda)	Nº de atributos
I	NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	22
II	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	25
III	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	23
IV	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	26
*IMFS V	NIR(8) - R(7) - G(6) - B(5) - PCA (8765)	22
*IMFS VI	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF	25
*IMFS VII	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA	23
*IMFS VII	NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA	26

NIR – canal do infravermelho-próximo; R (Red) – canal vermelho; G (Green) – canal verde; B (Blue) – canal azul; APC - Análise por Principais Componentes; NDVI - Índice de Vegetação da Diferença Normalizada; SAVI - Índice de Vegetação Ajustado ao Solo; IAF - Índice de Área Foliar; MDA - Modelo Digital de Altura. \*IMFS são as imagens fusionadas (R/G/B/NIR).

\*IMFS – Imagens fusionadas.

Fonte: Elaborado pelo autor (2021).

#### 4.4.7 Definição e caracterização das classes mapeadas

A definição dos diferentes contornos das fitofisionomias presentes na Zona de Amortecimento da REBIO Serra Negra, teve como referência as classes de uso e ocupação no solo observadas e interpretadas visualmente com base nas composições coloridas das imagens de satélite e Ortoimagens. Também foram consideradas as fitofisionomias das vegetações identificadas no levantamento florístico realizado por Rodal; Nascimento (2002) e Pereira *et al.* (2010), e nas descrições dada no Plano de Manejo da reserva biológica (ICMBio, 2011), e nos estudo de Cruz *et al.* (2005) e Freire *et al.* (2017). Foram estabelecidas as seguintes classes:

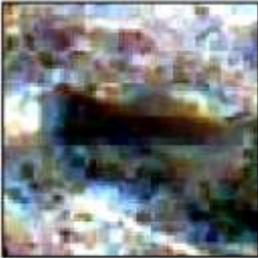
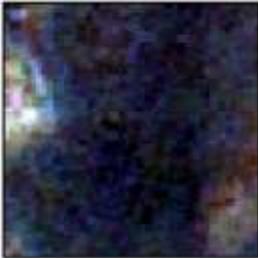
- Massas D'Água (MAG): inclui todas as classes de água, como cursos de água e canais, e reservatórios artificiais ou naturais;
- Solo Exposto (SEXP): são áreas sem a presença de cobertura vegetal ou outros tipos de cobertura que não seja o solo, presente tanto em ambientes naturais quanto antrópicos, incluído as vias sem pavimentação;
- Floresta de Altitude (FA): também denominada de Remanescente de Mata de Formação Orográfica, com predomínio da fitofisionomia de Floresta Estacional Subcaducifólia (FREIRE *et al.*, 2017), composta por floresta densa, com troncos grossos e retilíneos e emergentes de até 35 m, podendo manter boa parte de sua folhagem durante todo ano (RODAL; NASCIMENTO,

2002). De acordo com Pereira *et al.* (2010), esta área demonstrou também a existência de uma grande diversidade de espécies da Mata Atlântica e algumas espécies do domínio amazônico. No plano de manejo, a vegetação desta área é descrita com predomínio da Caatinga e Mata Ombrófila Densa (ICMBio, 2011);

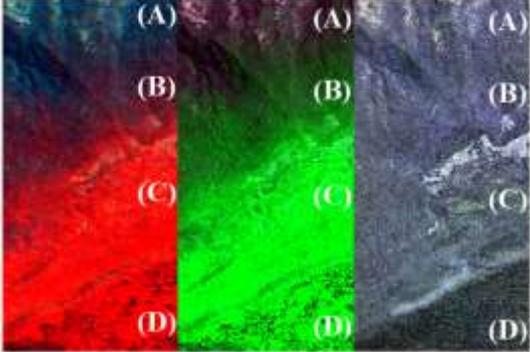
- Caatinga Arbustiva Densa (CAD): também chamada de Caatinga Arbórea, é composta tipicamente por um número maior de árvores e um adensamento do estrato arbustivo, interrompido somente em locais onde há afloramento rochoso (CRUZ *et al.*, 2005), vegetação muito densa, com ocorrência de espécies de porte arbóreo e arbustiva. Para esta classe foram criadas duas subclasses, sendo uma sobre predomínio de solos mais arenosos (CAD<sub>saren</sub>) e outra sobre maior influência de solos argilosos (CAD<sub>sarg</sub>);
- Caatinga Seca e Esparsa (CSE): são compostas por vegetação arbustiva que não forma aglomerados (não há densidade), são mais isolados e ocorre ausência das cactáceas, podendo possuir dois estratos, um mais alto e outro o mais baixo (CRUZ *et al.*, 2005). Esta classe também inclui áreas antropizadas, que estão em estágio médio e avançado de sucessão florestal. Também para esta classe foram criadas duas subclasses, de acordo com o predomínio do solo, sendo ele mais arenoso (CSE<sub>saren</sub>) e mais argiloso (CSE<sub>sarg</sub>);
- Área de Transição (AT): também conhecida como ecótono, são áreas de transição ambiental, onde as comunidades ecológicas diferentes entram em contato. Essa área de transição se localiza na escarpa setentrional (N/NO) que apresenta um declive abrupto, e na escarpa meridional (S/SE) que apresenta um declive mais suave (RODAL; NASCIMENTO, 2002), e nas regiões do entorno e do sopé da serra. Situada entre as áreas de Floresta de Altitude e Caatinga Arbustiva Densa, as ocorrências de diferentes fitofisionomias, tais como, do Cerrado, Caatinga Hipoxerófila e Floresta Caducifólia (FREIRE *et al.*, 2017). De acordo com Rodal; Nascimento (2002), nas áreas de escarpas da serra apresenta floresta aberta, possuindo árvores de até no máximo 20 m de altura, podendo ocorrer áreas com fragmentos de floresta densa, e na medida em que se afasta do topo, o ambiente se torna menos úmido, e há ocorrência de vegetação caducifólia espinhosa e rupícola em locais com afloramentos rochosos. Para esta classe foi realizada uma divisão em duas subclasses: **Área de Transição 1 (AT<sub>FA</sub>)**, sendo a primeira iniciando do topo da serra, situada nas áreas mais escarpadas, cuja vegetação é mais úmida e leva mais tempo para perder a folhagem durante os períodos desfavoráveis; **Área de Transição 2 (AT<sub>CDA</sub>)**, situada mais no sopé da serra, cuja vegetação perde mais rapidamente a folhagem e vai de encontro com a Caatinga Arbustiva Densa.

Ao total foram definidas nove classes de uso e ocupação do solo, que delimitavam o contorno das diferentes fitofisionomias presentes no entorno na Zona de Amortecimento da REBIO Serra Negra. Na Tabela 7, são apresentadas as classes selecionadas, e uma breve descrição de suas principais características nas imagens multiespectrais, câmera MUX e Ortoimagem.

**Tabela 7** -- Descrição e ilustração das classes mapeadas na área de estudo.

Classe	Composição (RGB/Ortoimagem)		Descrição
Massas D'Água (MAG)			São pequenas áreas de represamento de água.
Solo Exposto (SEXP)			São áreas sem nenhuma cobertura vegetal. Sendo que para essa região pode apresentar coloração mais avermelha (solos argilosos) ou branca (solos arenosos).
Floresta de Altitude (FA)			Floresta densa, podendo manter boa parte de sua folhagem durante todo ano.
Caatinga Arbustiva Densa (CAD <sub>saren</sub> )			Vegetação composta tipicamente por um número maior de árvores, e um adensamento do estrato arbustivo, sobre a influência de solos mais arenosos.
Caatinga Arbustiva Densa (CAD <sub>sarg</sub> )			Vegetação composta tipicamente por um número maior de árvores, e um adensamento do estrato arbustivo, sobre a influência de solos mais argilosos.

\*R(8)G(6)B(5)

Caatinga Seca e Esparsa (CSE <sub>saren</sub> )		Composta por vegetação arbustiva que não forma aglomerados e são mais isoladas, e está mais sobre a influência de solos arenosos.
Caatinga Seca e Esparsa (CSE <sub>sarg</sub> ):		Composta por vegetação arbustiva que não forma aglomerados e são mais isoladas, e está mais sobre a influência de solos argilosos.
Área de Transição (AT):		São áreas de transição ambiental, presentes nas áreas mais escarpadas da serra (AT <sub>FA</sub> ), e possuem vegetação mais úmida e leva mais tempo para perder a folhagem durante períodos desfavoráveis. São as áreas de transição do sopé da serra (AT <sub>CDA</sub> ), em que a vegetação perde mais rapidamente a folhagem e vai de encontro com a Caatinga Arbustiva Densa.

\*R(8)G(6)B(5) - R(5)G(8)B(6)  
 (A) - Caatinga Arbustiva Densa (CAD<sub>saren</sub>);  
 (B) - Área de Transição 2 (AT<sub>CAD</sub>); (C) - Área de Transição 1 (AT<sub>FA</sub>); (D) - Floresta de Altitude (FA).

Fonte: Elaborado pelo autor (2021).

#### 4.4.8 Amostragem

Para o processo de classificação por redes neurais é necessário possuir um conjunto amostral de referência, ou seja, possuir um conjunto de amostras classificados de acordo com as classes de interesse. A seleção dos conjuntos amostrais (segmentos contendo os atributos) não foi executada no *software* eCognition, pois foram geradas ao todo 16 projetos (oito para cada ano), não sendo viável a seleção das amostras na mesma posição geográfica em todos os resultados gerados utilizando o programa. Objetivando selecionar os segmentos (conjunto amostrais) situados na mesma posição geográfica e presente em ambos os anos de aquisição das imagens foi criado uma rotina de trabalho no *software* QGIS para atender a esse objetivo.

Também foi adotada as recomendações Congalton e Green (1999) e Piazza (2014), para seleção das amostras de treinamento e de validação, onde foram adotados os critérios: (1) seleção de objeto (segmentado) correspondente à única classe (objetos com mistura de classes

não foram selecionados); (2) seleção de amostras distribuídas uniformemente na área de estudo; e (3) apresentarem similaridade com áreas observadas em ambos os anos. Tentou-se obedecer ao número mínimo de 50 amostras por classe, definido por Congalton e Green (1999), para mapas cobrindo menos de um milhão de acres e com menos de 12 classes. No entanto, devido a áreas reduzidas de algumas classes, não foi possível a observância deste número para todas elas.

Para o procedimento de amostragem foram criados dois conjuntos amostrais do tipo de geometria de ponto, sendo um utilizado para o treinamento da rede neural, e o segundo para avaliar o resultado da classificação dos segmentos. O primeiro conjunto amostral foi composto por 800 pontos amostrais, criados de forma manual, distribuídos por todas as imagens (região de estudo), sendo representativos para sua respectiva classe e sendo identificáveis em ambas as imagens multiespectrais referentes aos anos de 2017 e 2019 e na Ortoimagem (Tabela 8). Esse primeiro conjunto de pontos amostrais foi utilizado para extração dos segmentos amostrais criados no procedimento anterior para treinamento da rede neural.

**Tabela 8** - Número de amostras criadas na geometria de pontos para classificação.

Classe	Número de amostras para classificação	
	2017	2019
FA	50	50
CAD <sub>saren</sub>	140	137
CAD <sub>sarg</sub>	107	102
CSE <sub>saren</sub>	131	128
CSE <sub>sarg</sub>	80	79
AT <sub>FA</sub>	61	61
AT <sub>CDA</sub>	84	84
SEXP	142	139
MAG	5	20
Total	800	800

Fonte: Elaborado pelo autor (2021).

Um segundo conjunto composto por 1000 pontos amostrais foi criado através de uma função de criação de “Pontos aleatórios” do *software* QGIS 3.10.2-A, cobrindo toda a área de estudo, com um raio mínimo de 100 m de distância, sendo utilizados para validação dos resultados da classificação (Tabela 9). Posteriormente, todos os pontos criados foram identificados (classificados), com base na descrição de cada classe: Massas D’Água (MAG), Solo Exposto (SEXP), Floresta de Altitude (FA), Caatinga Arbustiva Densa tipo 1 (solo mais arenoso - CAD<sub>saren</sub>) e 2 (solo mais argiloso - CAD<sub>sarg</sub>), Caatinga Seca e Esparsa tipo 1 (solo mais arenoso - CSE<sub>saren</sub>) e 2 (solo mais argiloso CSE<sub>sarg</sub>) e Área de Transição tipo 1 (AT<sub>FA</sub>) e 2

(AT<sub>CDA</sub>). O número de amostras por classe foram diferentes, devido algumas classes possuírem áreas representativas muito limitadas (Tabela 9).

**Tabela 9** - Número de amostras de referência.

Classe	Número de amostras de referência	
	2017	2019
FA	52	52
CAD <sub>saren</sub>	147	149
CAD <sub>sarg</sub>	135	133
CSE <sub>saren</sub>	153	151
CSE <sub>sarg</sub>	97	94
AT <sub>FA</sub>	113	111
AT <sub>CDA</sub>	147	147
SEXP	151	148
MAG	5	15
Total	1000	1000

Fonte: Elaborado pelo autor (2021).

A rotina de trabalho para extrair os segmentos amostrais de geometria do tipo polígono a partir dos pontos amostrais (geometria do tipo ponto), compreendeu a aplicação de quatro ferramentas disponibilizadas pelo *software* QGIS 3.10.2-A. Ao final deste procedimento, os segmentos amostrais e seus respectivos atributos foram extraídos, formaram uma nova camada (do tipo polígono), separando do conjunto original dos segmentos, e na sua tabela de atributos constará uma nova coluna com a identificação da respectiva classe.

O primeiro passo é a partir dos segmentos exportados do *software* eCognition Developer 9.2 no formato shapefile (.shp), onde aplica-se as seguintes funções: “**Corrigir Geometria**” para correção de geometrias inválidas; segundo passo é “**Extrair (segmentos) por Localização**”, este procedimento irá extrair os segmentos amostrais que pelo menos continha dentro do segmento um ponto amostral; seguido ao próximo passo de “**Unir atributo pela localização**”, esta ferramenta teve a função de classificar os segmentos amostrais, que continha dentro ao menos um ponto amostral, unindo as tabelas de atributos em suas respectivas classes; e por último a função de “**Excluir geometrias duplicadas**”, cuja função foi excluir segmentos duplicados ocasionados quando mais de um ponto amostral se localizava dentro de um mesmo segmento.

Ao final do procedimento foram extraídas as amostras dos 16 projetos criados, ambos no formato de arquivo Shapefile (.shp), com seus respectivos atributos (Tabela 10).

**Tabela 10** - Número de amostras por projetos.

	Entrada	Projeto	FA	CDA <sub>saren</sub>	CDA <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CD<sub>A</sub></sub>	SEXP	<sup>1</sup> MAG	Total
23/01/2017	I	1	17	123	91	125	64	42	63	126	-	651
	II	2	19	124	95	126	68	46	71	130	-	679
	III	3	23	126	94	127	65	48	69	133	-	685
	IV	4	22	124	99	129	66	51	72	128	-	691
	V	5	19	127	98	126	67	48	68	128	-	681
	VI	6	20	128	95	128	72	48	67	133	-	691
	VII	7	23	125	96	126	67	48	71	124	-	680
	VIII	8	23	128	98	126	71	47	70	133	-	696
20/08/2019	I	9	29	128	91	129	68	51	74	135	11	716
	II	10	21	125	98	125	70	53	75	135	11	713
	III	11	27	127	96	128	67	49	73	135	10	712
	IV	12	25	129	99	129	66	56	73	134	9	720
	V	13	21	124	98	126	62	44	71	132	11	689
	VI	14	25	132	97	126	68	46	71	128	10	703
	VII	15	22	129	99	127	71	53	74	130	11	716
	VIII	16	33	130	99	126	67	51	76	131	13	726

<sup>1</sup>MAG – não foram identificadas amostras suficientes para o ano base 2017.

Fonte: Elaborado pelo autor (2021).

Em seguida, a tabela de atributos dos arquivos amostrais e de todos os seguimentos foram exportados para o formato de arquivo da Planilha de cálculo MS Office Open XML (extensão XLSX) (**Figura 15**).

**Figura 15** - Exemplo de arquivo Microsoft Excel de extensão (XLSX), com seus respectivos atributos.

	A	B	C	D	E	F
1	GLCM Hom B8	GLCM Hom B7	GLCM Hom B6	GLCM Hom B5	GLCM Ent B8	GLCM Ent
2	0.16900509969498	0.16668955818041	0.27851319789115	0.24600491491583	3.51217843212041	3.50071033
3	0.03805910408826	0.03007121691493	0.05118056198620	0.12180548827942	4.73372512751027	5.23556328
4	0.18627672569513	0.12208920255614	0.18354073400149	0.20673679594430	3.22038648598341	4.01585164
5	0.16479078476621	0.15822984700511	0.21151918809649	0.26662188791618	3.32349423628192	3.59001704
6	0.19123979033765	0.12222777578705	0.19456936728085	0.23067786267815	3.57793652339695	3.73329461
7	0.13926290224367	0.11970399331821	0.19879780523022	0.26571622285794	3.66558772273116	3.75708056
8	0.14219699783927	0.12678656678176	0.17345793488257	0.24138515739906	3.38310018911101	4.00873133
9	0.15866218715162	0.13618983642684	0.17008148304253	0.28705080649342	3.71862658766509	3.87388152
10	0.12224359227330	0.11715998247371	0.16970654569671	0.23570311133158	3.87549580778573	3.75309131
11	0.14166547299597	0.11946250633330	0.19619467679025	0.24018122508266	3.65771312100773	3.74070205
12	0.18690042914519	0.13306710508642	0.18897364733426	0.26699149197583	3.00359098974401	3.48587935
13	0.21558804266570	0.17716812320071	0.32370813289617	0.28173916551538	2.96644281813792	3.03079963
14	0.12472451763304	0.09322129263121	0.12620011754870	0.15229409216101	4.09954323907921	4.62896575
15	0.13987421025154	0.13253131174208	0.20296851540916	0.22830936248994	3.65311579740820	3.97027011
16	0.14270236675400	0.10548521485344	0.14921658972454	0.23966508550767	3.81554673989559	4.10980834
17	0.16990774206153	0.13044017912377	0.19864774816741	0.32153150200811	2.93236389782939	3.73326155
18	0.12932825038276	0.11407122493642	0.16488756557017	0.26583319822390	3.84743006797766	4.08551390
19	0.10942540457689	0.10514330319379	0.17772117072765	0.26878566795225	3.96195311456524	4.07419202
20	0.12244177204611	0.10399257689385	0.14572847788170	0.22471791954863	3.95610142016119	4.18448225
21	0.22588828366054	0.22227722055666	0.35086658476561	0.34614240533190	3.04649068195836	2.84446880
22	0.14894984425476	0.16881498347924	0.28236432905380	0.34475937827413	3.57712168970583	3.46766367
23	0.18293489184173	0.15102038564679	0.26703719926643	0.27500426009392	3.56985621138129	3.55616886
24	0.23541904601251	0.22112774614220	0.38378607623128	0.30740738038034	2.85996619869525	2.92548374
25	0.15877006514958	0.22282303438554	0.34249719433522	0.42697484112785	3.52947777296911	2.61526951
26	0.24138176195450	0.23720620513260	0.36729321216368	0.30319037916792	2.97519481589929	2.95155811
27	0.19351720076213	0.21267622026664	0.29763708146963	0.26667796854514	3.36769261802147	3.22843542
28	0.19259541474889	0.22282481690087	0.37838929003710	0.32201041223177	3.31371227642568	2.74290972
29	0.19952587864857	0.15052894762977	0.23148417131835	0.24260872763245	3.35117064543290	3.66244005
30	0.21034360008778	0.20981458501993	0.31895345468155	0.27592360511633	2.79208583866319	2.80885113
31	0.12593366424236	0.12870349037353	0.13047126710609	0.23346343479598	3.54350544107244	3.65623343
32	0.19481390270851	0.21426910627480	0.33755379442480	0.29422809536597	3.24965710580364	2.78237617
33	0.18500544570947	0.16220025770841	0.24511426038229	0.29905541905280	3.37445592499443	3.41411674

Fonte: Elaborado pelo autor (2021).

Na sequência, efetuou-se uma limpeza dos dados da Planilha de cálculo MS Office Open XML (extensão XLSX), exportados na etapa anterior, deixando-os na formatação adequada para o início dos processamentos de mineração. A limpeza consistiu em apagar as colunas desnecessárias, deixando apenas os atributos selecionados para seus respectivos planos de informação, e convertendo os arquivos da extensão XLSX para o formato CSV (*Comma Separated Values* ou Valores Separados por Vírgula) (**Figura 16**).

**Figura 16** - Exemplo de arquivo de Valores Separados por Vírgula (CSV).

```

1 GLCM_Hom_B8, GLCM_Hom_B7, GLCM_Hom_B6, GLCM_Hom_B5, GLCM_Ent_B8, GLCM_Ent_B7, GLCM_Ent_B6, GLCM_Ent_B5
2 0.16900509969498,0.16668955818041,0.27851319789115,0.24600491491583,3.51217843212041,3.500710
3 0.03805910408826,0.03007121691493,0.05118056198620,0.12180548827942,4.73372512751027,5.235563
4 0.18627672569513,0.12208920255614,0.18354073400149,0.20673679594430,3.22038648598341,4.015851
5 0.16479078476621,0.15822984700511,0.21151918809649,0.26662188791618,3.32349423628192,3.590017
6 0.19123979033765,0.12222777578705,0.19456936728085,0.23067786267815,3.57793652339695,3.733294
7 0.13926290224367,0.11970399331821,0.19879780523022,0.26571622285794,3.66558772273116,3.757080
8 0.14219699783927,0.12678656678176,0.17345793488257,0.24138515739906,3.38310018911101,4.008731
9 0.15866218715162,0.13618983642684,0.17008148304253,0.28705080649342,3.71862658766509,3.873881
10 0.12224359227330,0.11715998247371,0.16970654569671,0.23570311133158,3.87549580778573,3.753091
11 0.14166547299597,0.11946250633330,0.19619467679025,0.24018122508266,3.65771312100773,3.740702
12 0.18690042914519,0.13306710508642,0.18897364733426,0.26699149197583,3.00359098974401,3.485879
13 0.21558804266570,0.17716812320071,0.32370813289617,0.28173916551538,2.96644281813792,3.030799
14 0.12472451763304,0.09322129263121,0.12620011754870,0.15229409216101,4.09954323907921,4.628965
15 0.13987421025154,0.13253131174208,0.20296851540916,0.22830936248994,3.65311579740820,3.970270
16 0.14270236675400,0.10548521485344,0.14921658972454,0.23966508550767,3.81554673989559,4.109808
17 0.16990774206153,0.13044017912377,0.19864774816741,0.32153150200811,2.93236389782939,3.733261
18 0.12932825038276,0.11407122493642,0.16488756557017,0.26583319822390,3.84743006797766,4.085513
19 0.10942540457689,0.10514330319379,0.17772117072765,0.26878566795225,3.96195311456524,4.074192
20 0.12244177204611,0.10399257689385,0.14572847788170,0.22471791954863,3.95610142016119,4.184482
21 0.22588828366054,0.22227722055666,0.35086658476561,0.34614240533190,3.04649068195836,2.844468
22 0.14894984425476,0.16881498347924,0.28236432905380,0.34475937827413,3.57712168970583,3.467663
23 0.18293489184173,0.15102038564679,0.26703719926643,0.27500426009392,3.56985621138129,3.556168
24 0.23541904601251,0.22112774614220,0.38378607623128,0.30740738038034,2.85996619869525,2.925483
25 0.15877006514958,0.22282303438554,0.34249719433522,0.42697484112785,3.52947777296911,2.615269
26 0.24138176195450,0.23720620513260,0.36729321216368,0.30319037916792,2.97519481589929,2.951558
27 0.19351720076213,0.21267622026664,0.297630708146963,0.26667796854514,3.36769261802147,3.228435
28 0.19259541474889,0.22282481690087,0.37838929003710,0.32201041223177,3.31371227642568,2.742909
29 0.19952587864857,0.15052894762977,0.23148417131835,0.24260872763245,3.35117064543290,3.662440
30 0.21034360008778,0.20981458501993,0.31895345468155,0.27592360511633,2.79208583866319,2.808851
31 0.12593366424236,0.12870349037353,0.13047126710609,0.23346343479598,3.54350544107244,3.656233
32 0.19481390270851,0.21426910627480,0.33755379442480,0.29422809536597,3.24965710580364,2.782376
33 0.18500544570947,0.16220025770841,0.24511426038229,0.29905541905280,3.37445592499443,3.414116
34 0.22257640844241,0.18961843658499,0.24291952610771,0.26179519783690,3.01082968116868,2.877836
35 0.18888581853283,0.16556884801730,0.21674570374609,0.26966913839812,3.28521263885471,3.362026
36 0.16455833377969,0.22134058098160,0.29651435487596,0.28798566892030,3.57675269813599,3.239363
37 0.15643266107929,0.16790532776478,0.18863864343149,0.21968780272152,3.41080738033120,3.379694

```

Fonte: Elaborado pelo autor (2021).

#### 4.4.9 Mineração dos dados

A seguir e apresenta a metodologia da etapa de mineração de dados.

##### 4.4.9.1 Preparação dos arquivos entrada para Mineração de Dados

Para o processo de mineração de dados foram utilizados o *software* WEKA (*Waikato Environment for Knowledge Analysis*), elaborado por meio da linguagem Java, de código aberto desenvolvido pela Universidade de Waikato na Nova Zelândia. Para o treinamento e a classificação dos dados utilizando o *software* WEKA foi necessário convertê-los para o formato padrão do *software*, denominado de Formato de Arquivo Atributo-Relação (*Attribute Relation*

*File Format - ARFF*), que descreve uma lista de instâncias que compartilham um conjunto de atributos (CARVALHO, 2011; SOTHE, 2015). A estrutura dos arquivos ARFF é composta por duas seções, no qual a primeira é definida pelo cabeçalho e em seguida a seção dos dados (TOLENTINO, 2019). Os atributos são divididos em duas categorias: os atributos categóricos, que indica a classe à qual instância (objeto) pertence; e os atributos preditivos (numéricos), que estão associados às respectivas classes (SOTHE, 2015; TOLENTINO, 2019).

Inicialmente, os arquivos preparados na etapa anterior no formato CSV, foram carregados na interface gráfica Explorer (Explorador de dados) do WEKA e salvos no formato padrão do ARFF (**Figura 17**).

**Figura 17** - Exemplo de arquivo ARFF.

```

1 @relation Amostras_Class1
2
3 @attribute GLCM_Hom_B8 numeric
4 @attribute GLCM_Hom_B7 numeric
5 @attribute GLCM_Hom_B6 numeric
6 @attribute GLCM_Hom_B5 numeric
7 @attribute GLCM_Ent_B8 numeric
8 @attribute GLCM_Ent_B7 numeric
9 @attribute GLCM_Ent_B6 numeric
10 @attribute GLCM_Ent_B5 numeric
11 @attribute Max_diff numeric
12 @attribute Standard_B8 numeric
13 @attribute Standard_B7 numeric
14 @attribute Standard_B6 numeric
15 @attribute Standard_B5 numeric
16 @attribute Mean_PCA_B4 numeric
17 @attribute Mean_PCA_B3 numeric
18 @attribute Mean_PCA_B2 numeric
19 @attribute Mean_PCA_B1 numeric
20 @attribute Mean_B8 numeric
21 @attribute Mean_B7 numeric
22 @attribute Mean_B6 numeric
23 @attribute Mean_B5 numeric
24 @attribute Brightness numeric
25 @attribute Nom_Class {CADbranca,CSEbranc,CSEverlh,SExp,FA,ATransFA,ATransCaat,CADverlh,MAG}
26
27 @data
28 0.169005,0.16669,0.278513,0.246005,3.512178,3.50071,2.901466,2.606349,0.892842,1.381638,1.3833,1.214
29 0.038059,0.030071,0.051181,0.121805,4.733725,5.235563,4.705062,3.546207,0.812856,2.747087,3.975549,2
30 0.186277,0.122089,0.183541,0.206737,3.220386,4.015852,3.212333,2.779371,0.875893,1.207349,1.958247,1
31 0.164791,0.15823,0.211519,0.266622,3.323494,3.590017,2.874747,2.663944,0.913704,1.21381,1.564649,1.1
32 0.19124,0.122228,0.194569,0.230678,3.577937,3.733295,3.112061,2.779412,0.885941,1.518373,1.765735,1.
33 0.139263,0.119704,0.198798,0.265716,3.665588,3.757081,2.871961,2.476278,0.884757,1.449217,1.567509,1
34 0.142197,0.126787,0.173458,0.241385,3.3831,4.008731,3.178542,2.580905,0.795363,1.284137,1.917035,1.2
35 0.158662,0.13619,0.170081,0.287051,3.718627,3.873882,3.121249,2.385334,0.808199,1.677918,1.70276,1.1
36 0.122244,0.11716,0.169707,0.235703,3.875496,3.753091,3.205833,2.779389,0.797563,1.685979,1.555681,1.
37 0.141665,0.119463,0.196195,0.240181,3.657713,3.740702,3.234358,2.56949,0.764021,1.523169,1.549109,1.

```

Fonte: Elaborado pelo autor (2021).

#### 4.4.9.2 Treinamento da RNA

A técnica de Mineração de Dados empregada se baseou nos métodos de Rede Neurais Artificiais (RNA) do tipo *Multilayer Perceptron* (MLP), também denominada Perceptron de Múltiplas Camadas, implementado no *software* WEKA. Foram utilizados os estudos de Botelho; Centeno (2005); Castanheira (2008), Sothe (2015); Tolentino (2019) para ajuste dos parâmetros da rede. As RNA implementadas no WEKA são do tipo perceptron e possui um conjunto de unidades sensoriais (neurônios), que formam a camada de entrada, uma ou mais camadas ocultas ou intermediárias e uma camada de saída (SILVA *et al.*, 2012). De acordo com Haykin (2001), esse tipo de rede é totalmente conectada, ou seja, todos os neurônios de qualquer camada estão conectados a todos os neurônios da camada anterior.

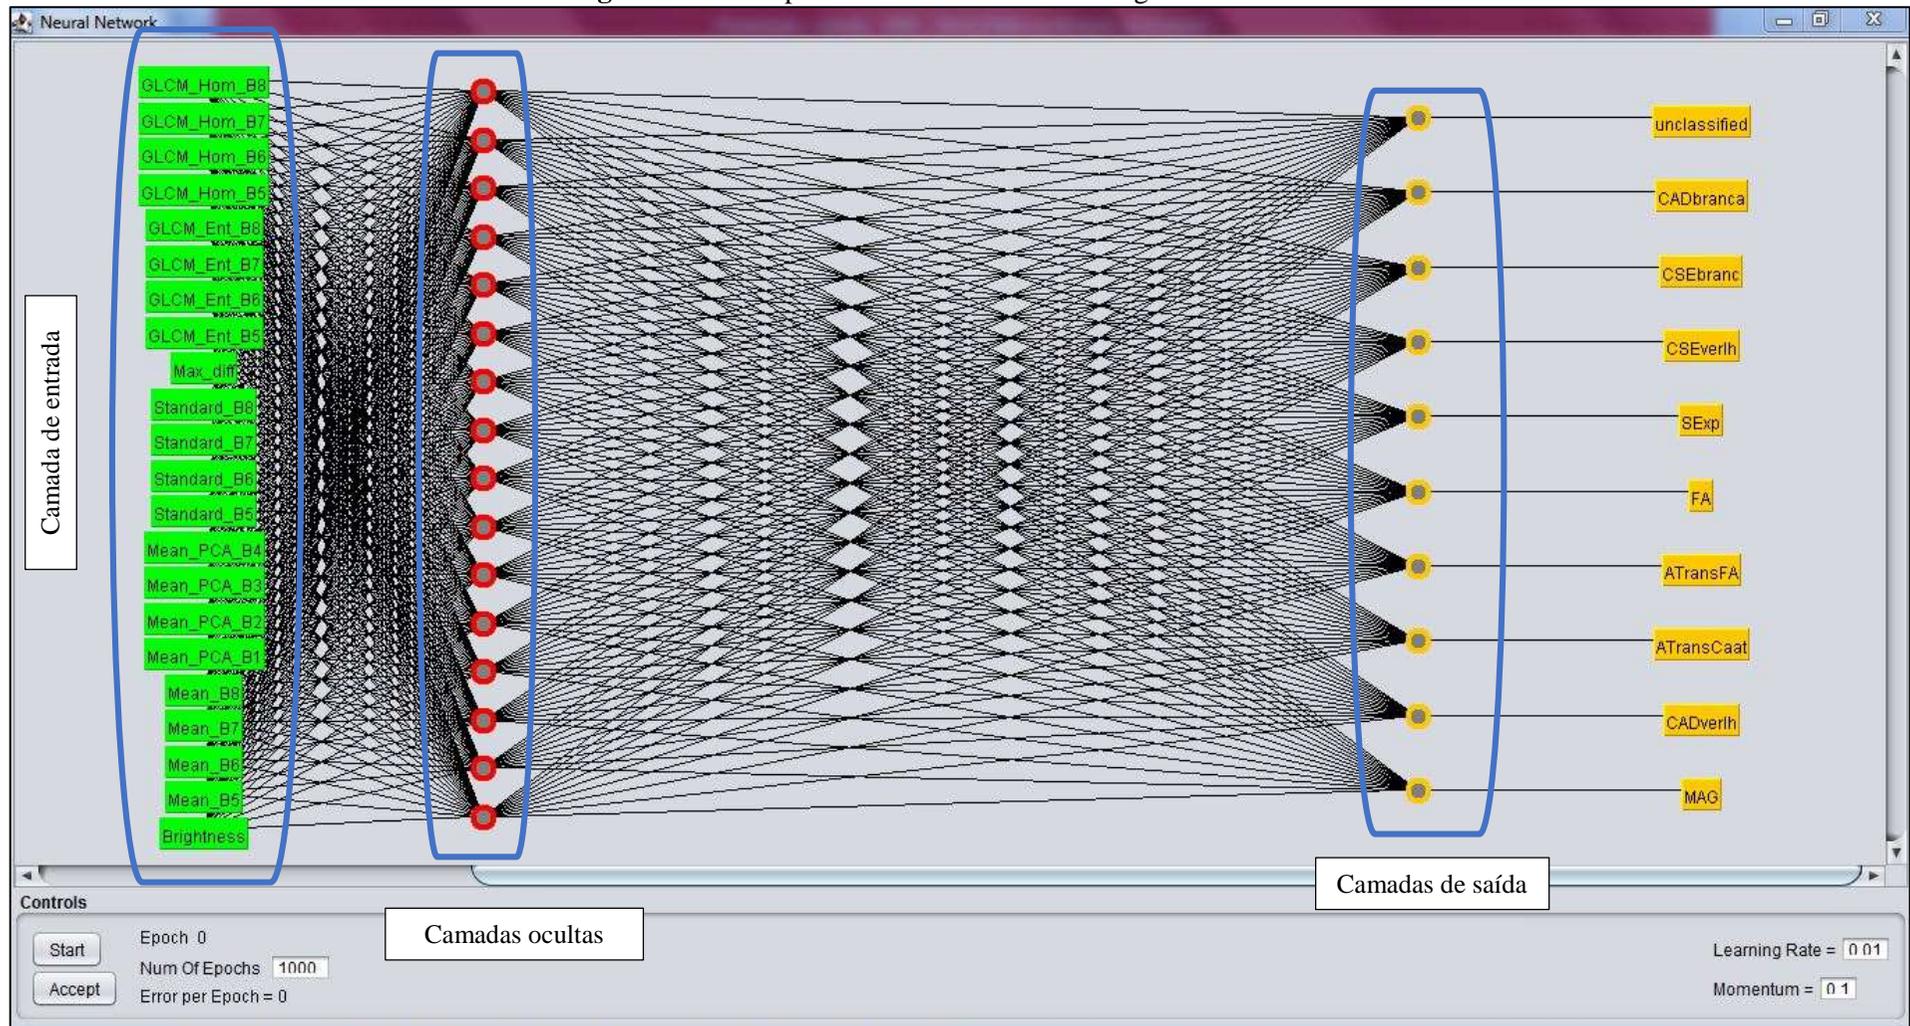
Por padrão, a rede RNA implementada no WEKA utiliza a função de ativação do tipo sigmoideal treinadas pelo algoritmo Backpropagation (retropropagação do erro). O número de camadas (neurônios) de entrada se deu em função do número de atributos considerados na classificação de cada projeto de entrada (Tabela 4 e 5), compostos pelas bandas multiespectrais em número digital, imagens das PCA, índices espectrais (NDVI, SAVI e IAF), e pelo MDA. O número de camadas de saída foi composto por nove neurônios, correspondente as classes mapeadas MAG, SEXP, FA, CAD<sub>saren</sub>, CAD<sub>sarg</sub>, CSE<sub>saren</sub>, CSE<sub>sarg</sub>, AT<sub>FA</sub> e AT<sub>CDA</sub>.

Foram realizados diferentes testes para identificar a melhor arquitetura da rede neural, ou seja, o número de camadas ocultas e/ou intermediárias, conforme o estudo de Andrade *et al.* (2003); Chagas *et al.* (2008) e Silva (2012). A arquitetura das camadas ocultas foi determinada através de tentativa e erro, bem como o número de neurônios em cada uma delas, conforme o procedimento estabelecido por Hirose *et al.* (1991). O número de camadas ocultas que melhor apresentou resultados se baseou na soma dos atributos de entrada mais o número de classes dividido por dois, resultando em única camada escondida (**Figura 18**).

Os demais parâmetros das RNA foram constantes para todos os testes. A taxa de aprendizagem ( $\alpha$ ) foi de 0,01; e a taxa do momento 0,1; e o número de ciclos (épocas) de treinamento como sendo 1000. A alocação aleatória dos pesos interneurônios foram iniciados com pequenos valores aleatórios entre -1 e 1. O critério de parada adotado para treinamento foi do tipo Cross-Validation (Validação Cruzada) com número 10 de validações cruzadas. De acordo com Witten *et al.*, 2011 e Bento (2017), a validação cruzada de 10 tem apresentado resultados satisfatórios sobre os diferentes conjuntos de dados, e diferentes técnicas de aprendizagem. Também foi tomada como verdadeira a função para normalizar os atributos, para

ajudar a melhorar o desempenho da rede. O ajuste dos parâmetros das RNA de treinamento levaram em conta a estatística do índice Kappa ( $K_p$ ) e o menor erro quadrático médio (EQM), obtido ao final de cada processo de treinamento no WEKA.

Figura 18 - Exemplo de Rede Neural Artificial gerada no WEKA.



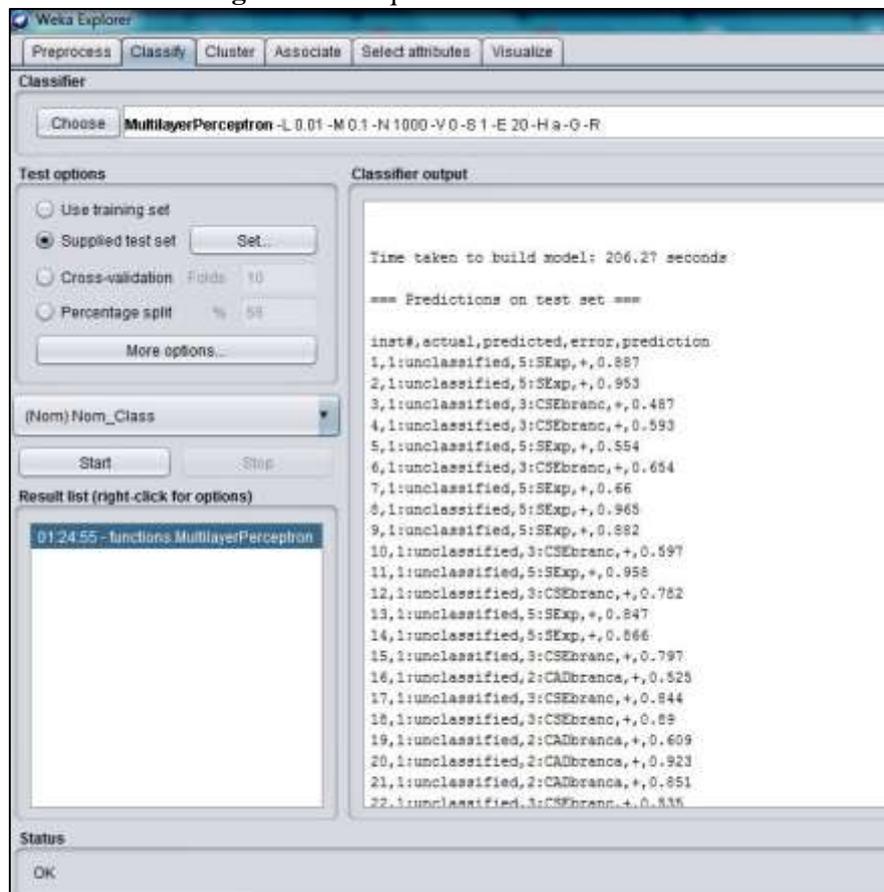
Fonte: Elaborado pelo autor (2021).

Ao final desse processo foram treinadas 16 RNA, correspondente as amostras dos 16 planos de informação (Tabela 4 e 5), com suas respectivas arquiteturas de camadas ocultas, e pesos ajustados que apresentaram os melhores desempenhos. A partir das redes treinadas foram classificados os demais segmentos do conjunto total de objetos (segmentos) gerados no *software* eCognition Developer 9.2. Essa etapa foi realizada no próprio WEKA, por meio da ferramenta “*Supplied test set*”, que classifica um conjunto de dados a partir da arquitetura de rede gerada anteriormente no processo de treinamento.

#### 4.4.10 Geração dos resultados finais

A classificação no *software* WEKA não gera uma imagem como resultado, já que ao final de cada processo, o *software* produz um arquivo de saída a qual indica as classes de saída previstas para cada segmento (objeto) da cena classificado, além do erro de predição a qual está associado a probabilidade de determinado segmento ter sido classificado corretamente (**Figura 19**). Este arquivo deve ser salvo no formato “Arquivo de Texto” (.txt), para posteriormente ser formatado no Excel.

**Figura 19** - Arquivo de saída WEKA 3.8.



Fonte: Elaborado pelo autor (2021).

Formatados os arquivos no Excel com os resultados, foi utilizado o *software* DBF Manager para ligar os segmentos no formato Shapefile (.shp) gerados no *software* eCognition Developer 9.2 com a respectiva classe do segmento gerado no WEKA. Esse procedimento é possível devido a ordem dos segmentos gerada no eCognition ser a mesma ordem gerada na classificação no WEKA.

Os mapas finais com os contornos das diferentes fitofisionomias da Zona de Amortecimento (proposta) do Remanescente de Mata de Formação Orográfica da REBIO Serra Negra, e entornos foram gerados a partir da ferramenta de “Dissolver” implementada no *software* QGIS 3.10.2-A. Esta ferramenta tem a função de unir segmentos (objetos) pertencentes a mesma classe.

#### ***4.4.11 Análise de sobreposição de classes***

A análise de sobreposição foi elaborada pelo Plugin através de cálculos de regras de decisão da Análise de Decisão de Multicritérios (rasterMCDA) baseados em raster, implementado no *software* QGIS. Essa análise consistiu em unir os oito planos de informação para um mesmo ano, formando uma imagem única, cujas classes que sobrepujessem receberia um valor diferente das classes que não se sobrepõem.

Para a utilização do Plugin rasterMCDA, primeiramente foram convertidas os arquivos com resultados da classificação do formato vetorial (seção anterior) para o formato raster, onde cada classe recebeu um valor numérico correspondente a sua respectiva classe. Posteriormente, as imagens geradas foram adicionadas ao plugin rasterMCDA, onde foram definidos os mesmos parâmetros (de peso e importância) para todas as camadas de entrada. Ao final do processo foi gerada uma imagem única, cujos valores dos pixels da nova imagem receberia um novo valor para cada classe que sobrepor, e um valor diferente para as classes que não se sobrepujessem.

#### ***4.4.12 Análise e avaliação da classificação***

Neste estudo não foi avaliada a qualidade da fusão de imagens, pois este não é objetivo da pesquisa. Utilizando-se os pontos de referência criados na etapa de amostragem foi avaliado a qualidade da classificação dos segmentos por meio da matriz de confusão e o respectivo cálculo da concordância do Kappa, Kappa condicional, exatidão global, exatidão do usuário e produtor. Também foram analisados os resultados visualmente para verificação da qualidade

da classificação (avaliação qualitativa), considerando o conhecimento existente sobre o uso e ocupação da Terra da área de estudo.

A matriz de confusão avalia os erros da classificação em relação aos dados de referência (RENNÓ *et al.*, 1999). A matriz é composta nas colunas pelas amostras de referência, identificadas com base nos pontos de validação interpretados nas Ortoimagens e imagens multiespectrais, e nas linhas, pelas classes obtidas na classificação. A matriz de confusão foi gerada pelo plugin “Accuracy Assessment” implementado no *software* QGIS 2.18.16. Para utilização do plugin, os segmentos classificados e as amostras de referência no formato vetorial foram convertidos para imagem raster através complemento “Converte vetor para raster (rasterizar)” também implementado no QGIS.

Cada classe recebeu um valor numérico correspondente (FA = 1; CAD<sub>saren</sub> = 2; CAD<sub>sarg</sub> = 3; CSE<sub>saren</sub> = 4; CSE<sub>sarg</sub> = 5; AT<sub>FA</sub> ATransFA = 6; AT<sub>CDA</sub> = 7; SEXP = 8; MAG = 9), esses valores representaram os valores dos pixels da imagem gerada. As resoluções espaciais foram 20 e 5 m, respectivamente correspondendo aos segmentos gerados pelas imagens entrada de 20 m e 5 m para as imagens fusionadas. O plugin “Accuracy Assessment” gera a matriz de confusão no formato de “Arquivo de Texto” (.txt), que posteriormente é exportada para o *software* Excel. Os demais índices foram calculados a partir da matriz utilizando a planilha do “Kappa 10Cond”, disponibilizada pelo INPE (2020). A planilha foi desenvolvida com base nas metodologias de Hudson; Ramm (1987) e Congalton (1999).

A concordância Kappa (K), também conhecida por coeficiente de Kappa, foi proposta por Jacob Cohen em 1960, com objetivo de avaliar o grau de concordância entre as proporções derivadas de amostras dependentes (FLEIS, 1981). O índice Kappa é dado por (Equação 14):

$$K = \frac{\sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} - n_{+i}}{n^2 - \sum_{i=1}^k (n_{i+} + n_{+i})} \quad (\text{Eq. 14})$$

em que: K é o índice Kappa (adimensional);  $n_{ii}$  é o número total de amostras corretamente classificadas da classe k;  $n_{i+}$  é o número total de amostras classificadas da classe k;  $n_{+i}$  é o número total de amostras coletadas da classe k; n é o número total de amostras.

O índice Kappa foi utilizado na avaliação da classificação dos segmentos e analisados de acordo com os intervalos de Landis e Koch (1977) (**Tabela 11**).

**Tabela 11** - Interpretação do índice Kappa.

Valores de Kappa	Interpretação
< 0	Ausência de concordância
0 - 0,19	Concordância pobre

0,20 - 0,39	Concordância leve
0,40 - 0,59	Concordância moderada
0,60 - 0,79	Concordância substantiva
0,80 - 1,00	Concordância quase perfeita

Fonte: Landis e Koch (1977).

O índice Kappa condicional avalia a acurácia individual de cada classe, sendo calculado com base no mesmo princípio do índice Kappa utilizado para a avaliação global da classificação dos segmentos, assim como a interpretação dos resultados obedecem aos mesmos princípios. Esse índice é dividido em Kappa condicional do usuário ( $K_u$ ) que avalia os erros de comissão (Equação 15), e o do produtor ( $K_p$ ), que avalia os erros de omissão (Equação 16) (ROSSITER, 2004). Sendo determinados pelas seguintes equações:

$$K_u = \frac{nn_{ii} - n_{i+} n_{+i}}{nn_{i+} - n_{i+} n_{+i}} \quad (\text{Eq. 15})$$

$$K_p = \frac{nn_{ii} - n_{i+} n_{+i}}{nn_{+i} - n_{i+} n_{+i}} \quad (\text{Eq. 16})$$

em que:  $K_u$  é o Kappa condicional do usuário (adimensional); Kappa condicional do produtor (adimensional);  $n$  é o número total de elementos de referência;  $n_{ii}$  é o número total de elementos classificados corretamente;  $n_{i+}$  é o total de elementos classificados para uma categoria  $i$ ;  $n_{+i}$  é o total de elementos de referência amostrados para uma categoria  $i$ .

Depois de obtidos os índices Kappa de cada classificação dos segmentos, foi realizado o teste  $z$  para testar a significância estatística da diferença entre as classificações resultantes de cada ano (2017 e 2019). Atribuiu-se um nível de significância de 5% ( $\alpha = 0,05$ ). A hipótese testada é se o Kappa é igual a 0, o que indicaria concordância nula, ou se ele é maior do que zero, concordância acima do esperado pelo simples acaso (para um teste monocaudal, tem-se, então:  $H_0: K = 0$ ;  $H_1: K > 0$ ). A hipótese de nulidade ( $K = 0$ ) ser rejeitada, a medida de concordância observada é significativamente maior do que zero, indicando, assim, a existência de concordância entre as classificações (SILVA; PAES, 2012). A estatística para testar a diferença entre as duas classificações (2017 e 2019), foi obtida pela equação 17:

$$z = \frac{K_1 - K_2}{\sqrt{\sigma_{K_1}^2 + \sigma_{K_2}^2}} \quad (\text{Eq. 17})$$

em que:  $K_1$  é o índice Kappa da classificação dos segmentos 1 (2017);  $K_2$  é o índice Kappa da classificação dos segmentos 2 (2019); e  $\sigma^2$  é a variância dos respectivos índices Kappas.

A exatidão global ( $E_G$ ) representa o número total de áreas classificadas corretamente, sendo determinada pela razão do número total da área (amostras) corretamente classificadas de cada classe dos segmentos classificados (soma dos elementos ao longo da diagonal principal da

matriz de confusão) e pelo número total da área (amostras) correspondente a cada classe dos pontos de referência (SOTHE, 2015) (Equação 18).

$$E_G = \frac{\sum_{i=1}^c n_{ii}}{n} \quad (\text{Eq. 18})$$

em que:  $E_G$  é a Exatidão Global (adimensional);  $n_{ii}$  é a soma das áreas (amostras) corretamente classificadas (elementos ao longo da diagonal principal da matriz de confusão);  $n$  é o número total da área (amostras) correspondente a cada classe dos pontos de referência.

A exatidão do usuário ( $E_u$ ) representa os erros de comissão, que indicam a probabilidade de um elemento classificado em uma determinada classe realmente possa pertencer a essa classe (LILLESAND *et al.*, 2004). É determinado pela razão entre as amostras classificadas corretamente pelo número de amostras atribuídos a esta classe (Equação 19).

$$E_u = \frac{n_{ii}}{n_{i+}} \quad (\text{Eq. 19})$$

em que:  $E_u$  é a exatidão do usuário (adimensional);  $n_{ii}$  número de amostras classificadas corretamente;  $n_{i+}$  é o número total de amostras classificadas para uma classe  $i$ .

Já a exatidão do produtor ( $E_p$ ) representa os erros de omissão, ou seja, a probabilidade de um objeto ser excluído (não classificado) da classe a que ele pertence. É determinado pela razão entre o número de amostras (neste caso, área) de uma classe classificada corretamente e o número total de amostras classificadas para esta classe (Equação 21) (CONGALTON; GREEN, 1999; LILLESAND *et al.*, 2004).

$$E_p = \frac{n_{ii}}{n_{+i}} \quad (\text{Eq. 21})$$

em que:  $E_p$  é a exatidão do produtor (adimensional);  $n_{ii}$  é o número de amostras classificadas corretamente;  $n_{+i}$  é o número total de amostras de referência para uma classe  $i$ .

#### **4.4.13 Análises gerais**

Após análises dos resultados da classificação por meio da matriz de confusão e dos respectivos índices de concordância, também foi feita uma análise geral para avaliar a influencias das bandas multiespectrais, índices espectrais e MDA para a discriminação das classes. Foram elaborados testes de significância e análises descritivas para comparar os atributos utilizados para discriminação das classes, com intuito de identificar os melhores descritores para a classificação.

Para o teste de significância foram comparadas as medidas de tendência central (mediana) entre os pares das classes mapeadas, utilizando-se a amostragem de referência. Para

seleção do teste adequado, a amostragem passou pelo teste de normalidade de Shapiro-Wilk, com objetivo avaliar se a mesma possuía distribuição normal. Confirmada a hipótese que os dados não possuem uma distribuição normal, utilizou-se o teste não paramétrico para amostras independentes para comparações de pares, conhecido como Teste Soma de Postos de Wilcoxon (Mann-Whitney), disponível no *software* RStudio versão 1.3.1093. Esse teste é utilizado para comparar se dois grupos possuem a mesma medida de tendência central (mediana), levando em consideração a magnitude das diferenças entre os pares. Ao nível de significância de 5% ( $\alpha = 0,05$ ), testa-se a hipótese nula ( $H_0$ : p-valor  $\leq \alpha$ ); se rejeitada, a diferença entre as medianas são estatisticamente significativa entre os pares comparados, quando para hipótese alternativa ( $H_1$ : p-valor  $> \alpha$ ); a diferença entre as medianas não são estatisticamente significativa. Ao final dos testes foram montadas as tabelas entre os pares com seus respectivos resultados.

## 5 RESULTADOS E DISCUSSÃO

Os resultados obtidos na pesquisa são apresentados nos diferentes tópicos abaixo, a fim de se obter maior clareza e organização dos principais resultados obtidos.

### 5.1 SEGMENTAÇÃO

Os parâmetros ideais para segmentação podem variar de região para região, e de acordo com a época das imagens analisadas. A existência de áreas muito fragmentadas e heterogêneas leva ao uso de valores de escala menores, de forma que cada objeto formado contenha apenas pixels da mesma classe (SILVA, 2012). Como a área em questão possui paisagens diversas entre áreas planas e montanhosas, e diferentes tipos de cobertura, optou-se por escolher visualmente os parâmetros que produziram as melhores segmentações. No sistema eCognition Developer 9.2 a segmentação é composta por quatro parâmetros: forma, compacidade, escala e peso das bandas, que deve ser ajustados de acordo com a finalidade do estudo.

Baseados nos estudos de Francisco; Almeida (2012); Castro *et al.* (2017); e Branco *et al.* (2018), foram testados diferentes valores entre os intervalos de 0,1 - 0,5 para o parâmetro de forma; 0,1 - 0,8 para a compacidade; e de 5 - 40 para o fator de escala. A verificação das diferentes combinações para os parâmetros foi feita através da análise visual, comparando se a forma e o tamanho dos objetos formados, bem como sua representatividade, relacionando com as classes da legenda (**Tabela 7**). Foi constatado que na medida em que se aumentava o parâmetro forma, a segmentação afastava-se do objetivo do trabalho, formando objetos bastante heterogêneos, por outro lado, valores menores, segmentavam muitos objetos aumentando a complexidade do processamento. Já em relação ao parâmetro compacidade, notou-se que com o aumento do critério, menos objetos eram contornadas (unindo duas classes dentro do mesmo objeto).

Seguindo as recomendações de Francisco; Almeida (2012), e tendo em vista que os parâmetros de forma e cor são complementares (cor = 1 - forma), atribuiu-se maior importância ao parâmetro de cor (0,9) na segmentação, assumindo um fator de forma de 0,1. Para os parâmetros de compacidade e suavidade, que também são complementares foi atribuído o mesmo valor 0,5. Independentemente dos oitos planos de informação e dos dois anos analisados, os parâmetros de forma e compacidade (0,1 e 0,5 respectivamente) foram os

mesmos para todos os planos de informação, diferenciando apenas no parâmetro de escala **Tabela 12** - Resultados finais da segmentação multirresolução.(**Tabela 12**).

A diferença nos fatores de escala concedeu-se para compensar as diferenças entre as resoluções espaciais e temporais das imagens base, objetivando manter a mesma proporção de segmento por área. Para os planos de informação do ano base 2017, as escalas foram maiores em relação ao ano base 2019, a fim de evitar uma super segmentação das imagens, devido a diferença da época de aquisição (ao final período seco e chuvoso, respectivamente). Foram testados valores de escala entre o intervalo 5 a 40, sendo que para os planos de informação, que utilizava as imagens fusionadas, o MDA era sempre maior.

**Tabela 12** - Resultados finais da segmentação multirresolução.

Planos de informação	Ano base - 2017		Ano base - 2019		Discrepância	
	Escala	Nº Segmentos	Escala	Nº Segmentos	Escala	Nº Segmentos
I	8	6358	7	6874	1	-516
II	7	6553	7	6396	0	157
III	30	6931	27	6314	3	617
IV	27	6392	22	6788	5	-396
IMFS V	36	6666	30	6285	6	381
IMFS VI	28	6776	24	6503	4	273
IMFS VII	32	6916	27	6584	5	332
IMFS VIII	27	6493	23	6543	4	-50

\*IMFS - Imagens fusionadas.

Fonte: Elaborado pelo autor (2021).

Notou-se que a diminuição ou aumento de uma unidade no fator de escala poderia provocar uma redução, ou acréscimo de  $\pm 152\%$  no número de segmentos gerados, tornando-se necessário a compensação do fator de escala para um mesmo nível de plano de informação. A compensação do fator de escala manteve o número de segmentos em torno da média (6586), sendo as maiores discrepâncias observadas para um mesmo nível de plano de informação originado pelas imagens não fusionadas. Para as imagens fusionadas do ano base 2017, o número de segmentos gerados foram maiores, ao contrário do que ocorreu para as imagens fusionadas do ano base 2019.

Os pesos das bandas e índices espectrais e MDA também foram determinantes para segmentação adequada. Não foi possível estabelecer uma relação direta entre o número de segmentos por plano de informação com os valores dos pesos adotados (Tabela 13). A adoção de maiores pesos para o MDA e NDVI e SAVI não diferenciaram muito quando comparados com os pesos das bandas multiespectrais. O peso do IAF foi o que menos contribuiu para formação dos objetos.

**Tabela 13** - Pesos atribuídos aos planos de informação

<b>Plano de Informação</b>	<b>B</b>	<b>G</b>	<b>R</b>	<b>NIR</b>	<b>NDVI</b>	<b>SAVI</b>	<b>IAF</b>	<b>MDA</b>
I	1	1	1	1	-	-	-	-
II	0.5	0.5	0.8	0.8	1	1	0.5	-
III	0.8	0.8	0.8	0.8	-	-	-	1
IV	0.5	0.5	0.8	0.8	1	1	0.5	1
IMFS V	1	1	1	1	-	-	-	-
IMFSS VI	0.5	0.5	0.8	0.8	1	1	0.5	-
IMFS VII	0.8	0.8	0.8	0.8	-	-	-	1
IMFS VIII	0.5	0.5	0.8	0.8	1	1	0.5	1

\*IMFS - Imagens fusionadas.

Fonte: Elaborado pelo autor (2021).

Os valores dos pesos atribuídos neste trabalho seguiu a recomendação de Baatz e Schäpe (2000) e Sothe (2015), onde os valores dos pesos foram atribuídos às camadas de acordo com o seu grau de importância para o processo de segmentação, sendo adotado para esta pesquisa maiores pesos os dados do MDA e índices espectrais do NDVI e SAVI. Na literatura encontra-se alguns trabalhos, na qual foram dados maior importância aos dados multiespectrais e índices espectrais, utilizando os MDT/MDE/MDS ou MDA apenas como atributos auxiliar para o processo de classificação. Silva (2012), por exemplo, utilizando imagens do LANDSAT – 7 TM, Repideye e MODIS, atribuiu peso 1 apenas para as bandas multiespectrais e para banda Red-Edge do satélite Repideye. Já Francisco e Almeida (2012), utilizando imagens ALOS/AVNIR-2, ALOS/PRISM e MDE TOPODATA, atribuíram pesos iguais (1) apenas para as bandas multiespectrais (NIR\R\G\B) e para imagens do NDVI. Em ambos os casos, observou-se que os pesos foram adotados de acordo com a pertinência das bandas para seus estudos.

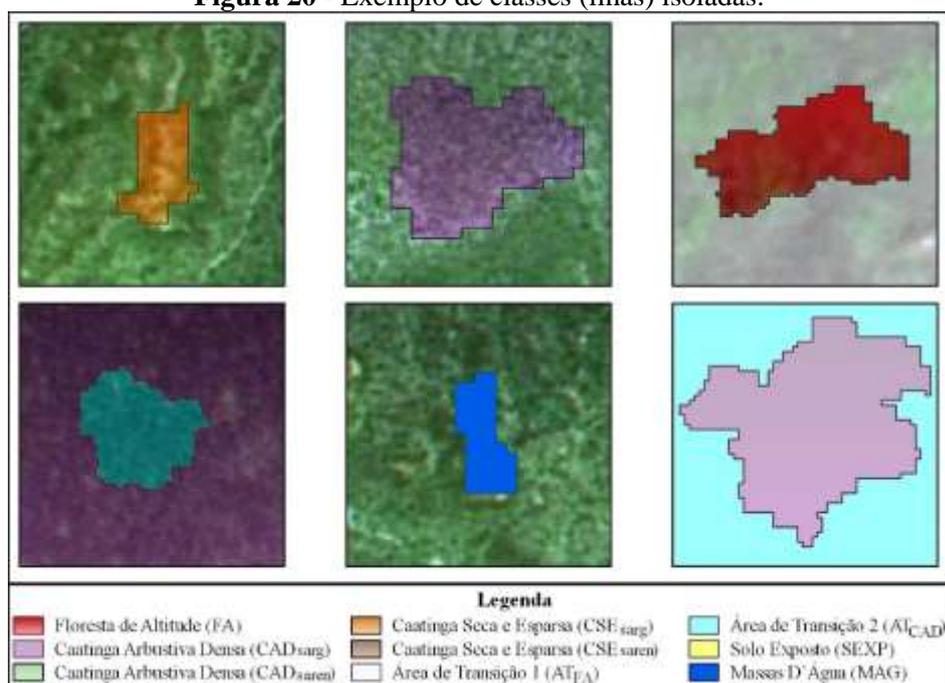
Em geral, a segmentação multirresolução baseada nos princípios da GEOBIA, foi satisfatória para atender o nível de detalhamento almejado nesta pesquisa. Todas as bandas multiespectrais, índices espectrais (NDVI, SAVI e IAF) e MDA e parâmetros segmentação influenciaram nos resultados. A segmentação também foi fortemente influenciada pelas resoluções espaciais e temporais das imagens de origem. A resolução espacial teve forte influência para formação de objetos menores, e identificação de classes isoladas (clareiras) quando utilizadas as imagens fusionadas. Enquanto à resolução temporal teve maior influência na formação dos contornos das áreas de transição (AT<sub>FA</sub> e AT<sub>CDA</sub>), ocasionados pela dinâmica da vegetação, tendo como base as imagens originadas ao final do período seco (2017) e chuvoso (2019). Dessa forma, não foi possível concluir qual plano de informação apresentou o melhor

nível de segmentação, pois em todos os casos, os resultados da segmentação foram bem sucedidos. De acordo com Garofalo *et al.* (2015), embora a classificação orientada a objetos seja mais amplamente aplicada em imagens de alta resolução espacial, os resultados obtidos nesta pesquisa mostram a robustez do método também para imagens de média resolução espacial.

## 5.2 CLASSIFICAÇÃO DOS DADOS

Foram gerados 16 mapas com delimitação dos contornos das diferentes fitofisionomias da vegetação e áreas antrópicas da Zona de Amortecimento proposta no plano de manejo da Reserva Biológica de Serra Negra (**Figura 21, 22, 23 e 24**). Assim, testaram-se diferentes planos de informação entre as bandas multiespectrais, índices espectrais (NDVI, SAVI e IAF) e MDA (**Tabela 4**). Percebe-se que a partir da utilização dos métodos de segmentação multirresolução e classificação por mineração de dados, todos os resultados obtidos atingiram aos objetivos propostos, e tanto na análise visual e estatística apresentaram semelhança nos resultados.

De modo geral, a classificação dos planos de informação gerados com base nas imagens referentes ao ano base de 2019, foram melhores em relação as imagens proveniente do ano base de 2017, com exceção apenas da classe de FA. Também para os planos de informação com base no ano 2019, os diferentes contornos foram melhores delimitados, além da ocorrência da menor formação de ilhas (classes) isoladas. Para os planos de informação com base no ano 2017, houve a formação de ilhas isoladas principalmente entre as áreas de CAD e CSE (**Figura 20**). Também para esse mesmo ano (2017), não foram identificadas áreas de MAG. Para os planos de informação do ano base 2019, houve identificação de várias áreas de represamento de água, classificadas como MAG em meio a áreas de CAD e CSE.

**Figura 20** - Exemplo de classes (ilhas) isoladas.

Fonte: Elaborado pelo autor (2021).

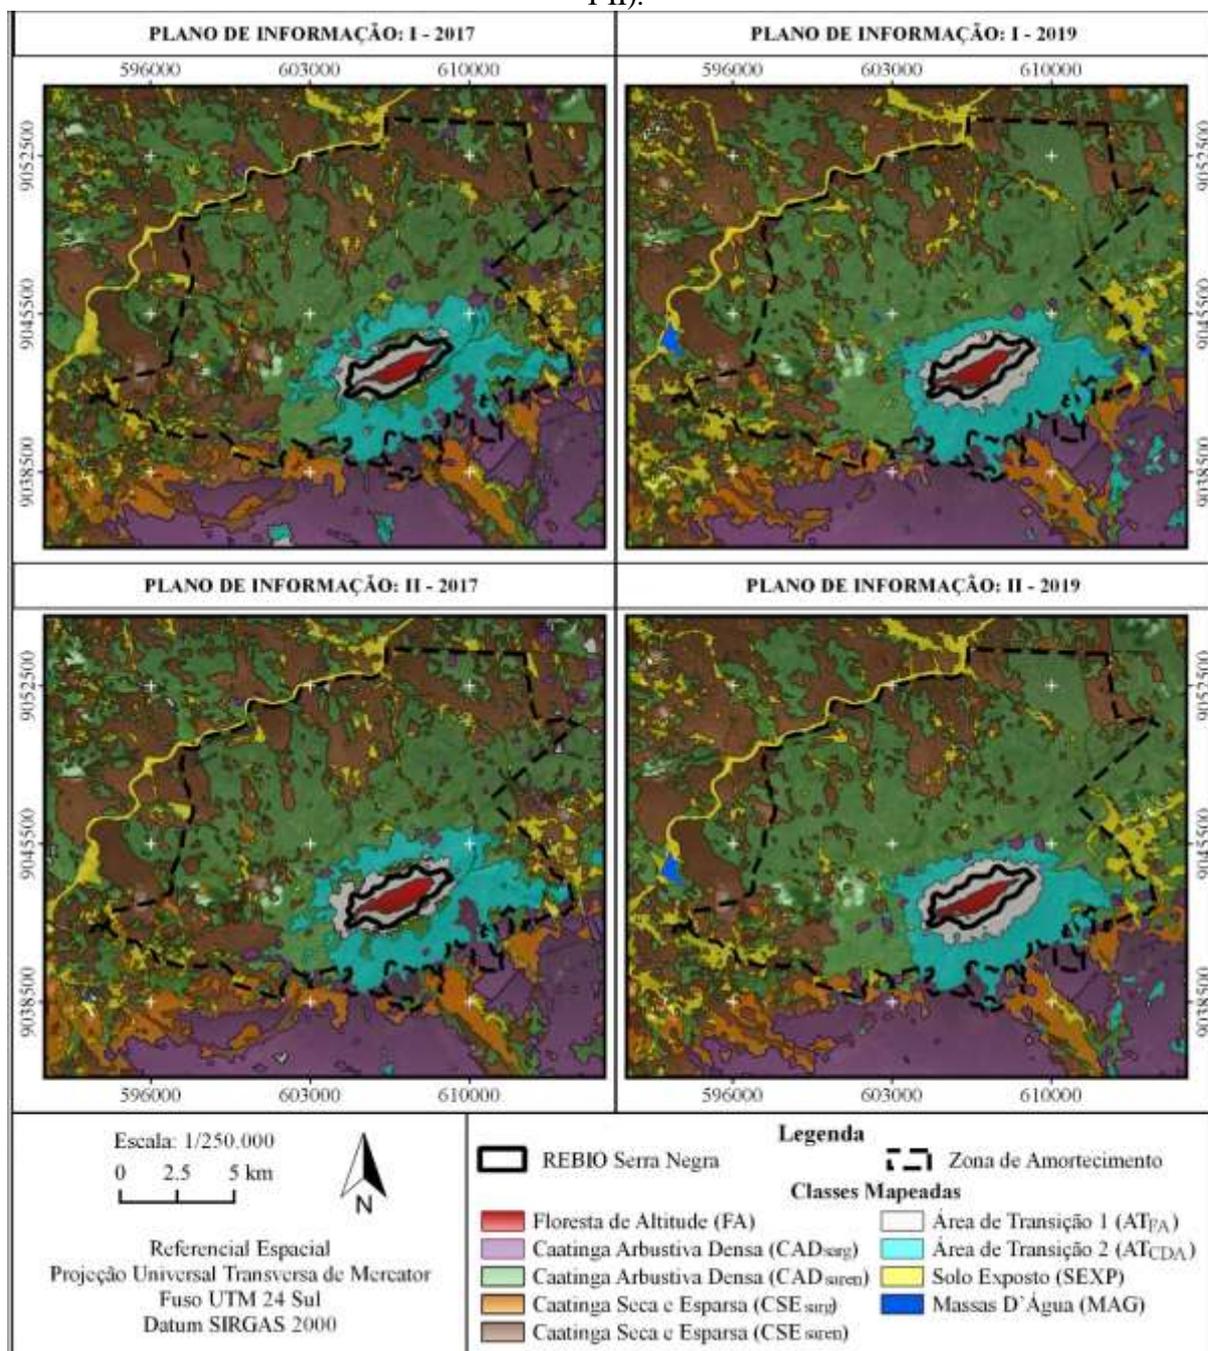
Os contornos das classes de área de transição (AT<sub>FA</sub> e AT<sub>CAD</sub>) apresentaram maiores dificuldades para serem delimitadas, principalmente para as camadas derivadas das imagens proveniente do ano base de 2017. Essas classes também apresentaram contornos muito diferentes entre o ano de 2017 e 2019, principalmente considerando os diferentes planos de informação. As dificuldades encontradas para a definição do limite dessa classe, ocorre justamente na área de maior dinâmica da cobertura vegetal e na região de escarpa da serra.

Segundo um levantamento de Rodal e Nascimento (2002), nestas áreas de escarpa da Serra apresenta floresta mais aberta, podendo ocorrer áreas com fragmentos de floresta densa, e na medida em que se afasta do topo, o ambiente se torna menos úmido, e há ocorrência de vegetação caducifólia espinhosa e rupícola em locais com afloramentos rochosos. De acordo com o levantamento de Freire *et al.* (2017), há ocorrências de diferentes fitofisionomias do Cerrado, Caatinga Hipoxerófila e Floresta Caducifólia para essa área. Tais características da vegetação são fortemente influenciadas pela temperatura e precipitação, o que afeta diretamente na definição do limite dessas classes. Houve também a identificação da AT em meio a área de CAD e CSE, em maiores proporções para os planos de informação referentes ao ano base de 2017. Os limites da área de transição, que mais se aproximou da realidade de campo foram identificados com base nas imagens derivadas do ano base de 2019.

Nas figuras a seguir encontra-se apresentado os resultados finais do mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (**Figura 21** a 24). Neste primeiro conjunto

de imagens (**Figura 21**), foram levados em conta os planos de informação I e II, composto pelas bandas multispectrais do NIR(8), R(7), G(6) e B(5) e pelas imagens das Principais Componentes PCA (8765), além das imagens dos índices espectrais (NDVI, SAVI e IAF).

**Figura 21** - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: I-II).



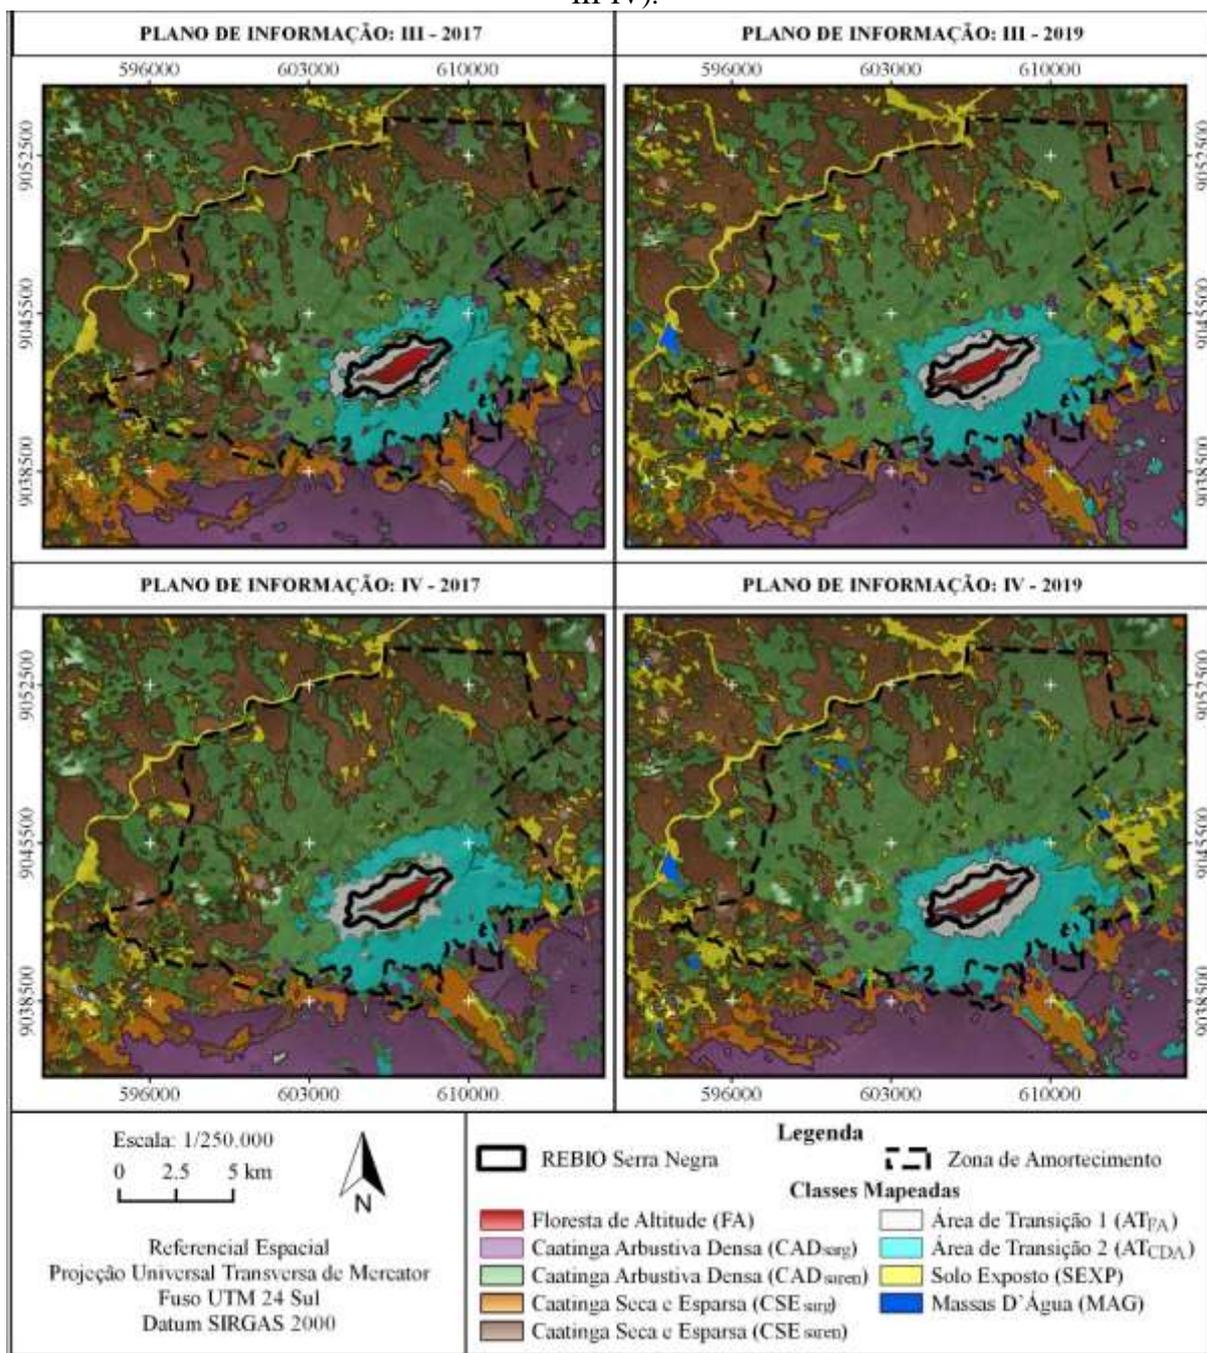
\*Plano de informação I: NIR(8) - R(7) - G(6) - B(5) - PCA (8765).

\*\*Plano de informação II: (NIR(8) - R(7) - G(6) - B(5)) - PCA (8765) - NDVI - SAVI - IAF.

Fonte: Elaborado pelo autor (2021).

Na **Figura 22** a seguir está representado o resultado dos planos de informação III e IV, que levaram em conta além das bandas multiespectrais do NIR(8), R(7), G(6), B(5) e das imagens das Principais Componentes PCA (8765) e índices espectrais (NDVI, SAVI e IAF) o MDA.

**Figura 22** - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: III-IV).



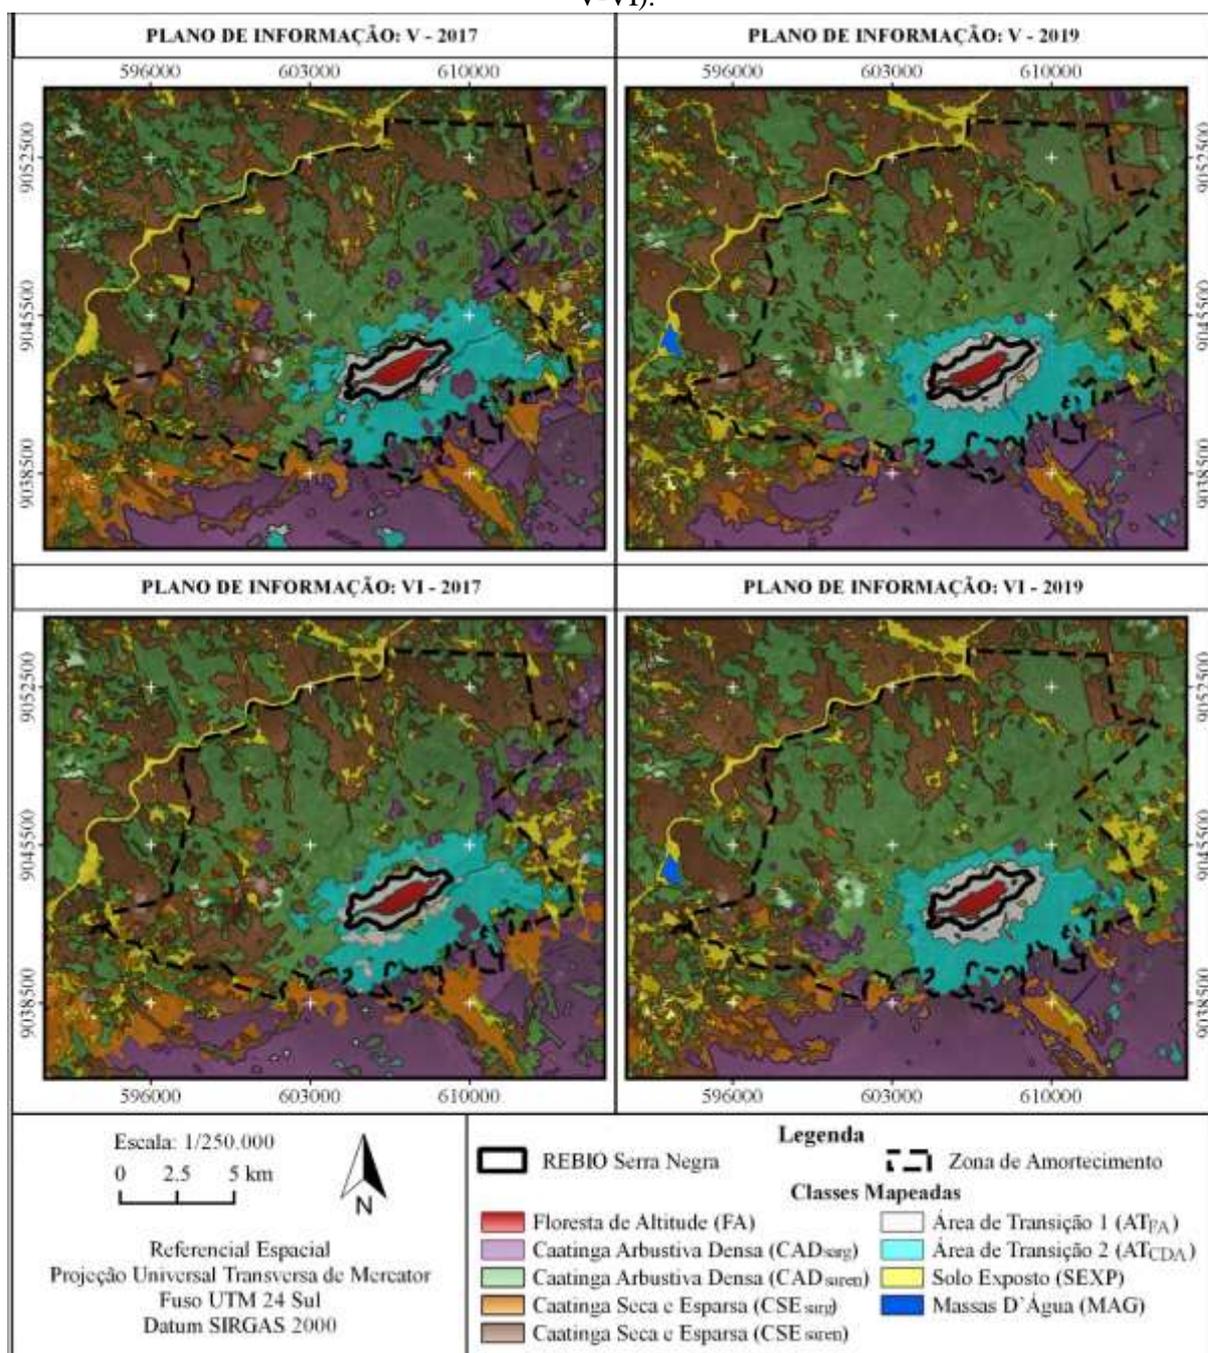
\*Plano de informação III: NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA;

\*\*Plano de informação IV: (NIR(8) - R(7) - G(6) - B(5)) e pelas PCA (8765) - NDVI - SAVI - IAF - MDA.

Fonte: Elaborado pelo autor (2021).

Já na figura abaixo, encontra-se apresentado o resultado dos planos de informação V e VI (**Figura 23**), que levaram em conta as bandas multiespectrais fusionadas NIR(8), R(7), G(6), B(5) e suas respectivas imagens das Principais Componentes PCA (8765) e índices espectrais (NDVI, SAVI e IAF).

**Figura 23** - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: V-VI).



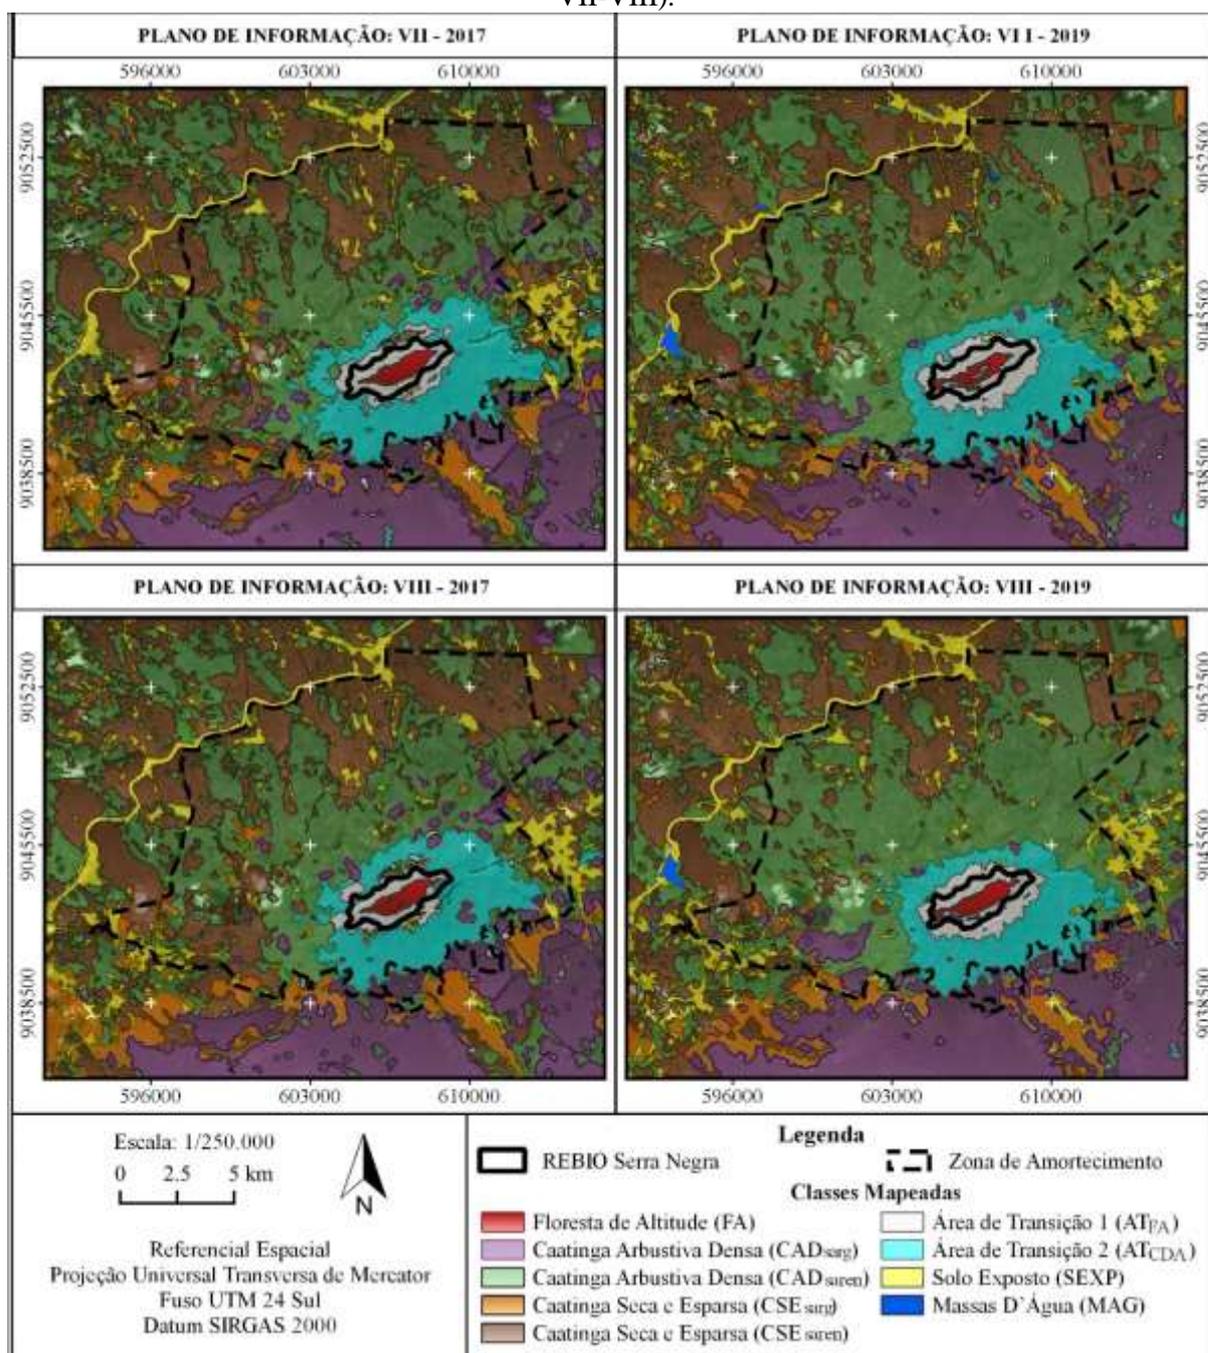
\*Plano de informação V: IMFS NIR(8) - R(7) - G(6) - B(5) - PCA (8765).

\*\*Plano de informação VII: IMFS(NIR(8) - R(7) - G(6) - B(5)) e pelas PCA (8765) - NDVI - SAVI - IAF.

Fonte: Elaborado pelo autor (2021).

No último conjunto de figura foi apresentado o resultado final dos planos de informação VII e VIII (**Figura 24**), compostas pelas bandas multiespectrais fusionadas NIR(8), R(7), G(6), B(5) e suas respectivas imagens das Principais Componentes PCA (8765) e índices espectrais (NDVI, SAVI e IAF) o pelo MDA.

**Figura 24** - Mapeamento dos contornos das diferentes fitofisionomias da vegetação e áreas antropizadas da Zona de Amortecimento da Reserva Biológica de Serra Negra (Plano de informação: VII-VIII).



\*Plano de informação VII: <sup>IMFS</sup> NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA;

\*\*Plano de informação VIII: <sup>IMFS</sup>(NIR(8) - R(7) - G(6) - B(5)) e pelas PCA (8765) - NDVI - SAVI - IAF - MDA.

Fonte: Elaborado pelo autor (2021).

As áreas de FA foram muito bem identificadas considerando todos os planos de informação, sendo que as imagens do ano base de 2017, apresentaram os melhores contornos para identificação dessa classe. As maiores dificuldades para definição do limite dessa classe ocorreram nas bordas da escarpa meridional (S/SE), que apresenta um declive mais suave. Observou-se também que em regiões próximas a represamento (MAG), e de cursos d'água perenes e intermitentes ocorreram a formação de ilhas úmidas em meio a áreas de CAD e CSE, sendo classificadas como áreas FA. Já nas áreas de transição ( $AT_{FA}$  e  $AT_{CAD}$ ), ocorreu a formação de ilhas de áreas de FA formada por pequenos fragmentos arbóreos de maior porte (altura).

Devido a diferença da data de aquisição das imagens entre o final do período seco (2017) e o período chuvoso (2019), respectivamente, as áreas anteriormente classificadas como áreas de CSE foram incluídas em áreas de CAD. Já as áreas antropizadas foram incluídas nas classes de SEXP e/ou CSE. Os contornos das áreas de  $CSE_{sarg}$  variaram bastante em relação ao ano de 2017 e 2019, e entre os planos de informação, apresentando grandes dificuldades para identificar seus limites. Em geral, a classe de solo exposto (SEXP) foi melhor identificada considerando todos os planos de informação em ambos os anos (2017 e 2019), seguida pela classe  $CAD_{sarg}$ ,  $CAD_{saren}$  e  $CSE_{saren}$ .

A melhoria da resolução das imagens pela técnica de fusão de imagens pelo algoritmo Pansharpening RCS (Substituição de Componente de Proporção), foi significativa, porém nesta pesquisa não foi avaliada a perda ou ganho da consistência espectral das imagens resultantes. A escolha do método de fusão levou em consideração os fatores propostos por Rodrigues e Kux (2015), que levam em conta a acessibilidade aos algoritmos de fusão; a capacidade de utilização de todas as quatro bandas multiespectrais, preservação da qualidade das imagens multiespectrais, assim como a manutenção dos detalhes da imagem pancromática na nova imagem obtida. A maior contribuição das imagens multiespectrais fusionadas foi para identificação de clareiras (classe isoladas menores que 400 m<sup>2</sup>), de áreas antropizadas e de SEXP em meio a classes predominantes de  $CSE_{saren}$  e  $CSE_{sarg}$ .

Conforme as descrições dadas no Plano de Manejo da REBIO Serra Negra, nas áreas do topo da Serra, nas áreas de FA há ocorrência de agrupamentos esparsos de espécies exóticas, como; eucalipto, jaqueiras e inúmeros exemplares de cafeeiros (*Coffea arabica*), referentes a culturas antigas e abandonadas (BRASIL, 2011a). Para todos os planos de informação testados, mesmo com as imagens fusionadas não foi possível diferenciar essas áreas de ocorrência de espécies exóticas e áreas de FA. Constatou-se que para algumas áreas foi observado a

ocorrência de clareiras, onde a vegetação foi totalmente suprimida para a construção de forma rudimentar, de pequenos cercados para a criação de bovinos e outros animais ao longo de toda Zona de Amortecimento. Observou-se também várias trilhas ao longo de toda a UC, denotando a constante presença humana (BRASIL, 2011a). Nos planos de informação essas áreas de clareiras foram melhor identificadas para as imagens fusionadas, sendo classificadas com áreas de SEXP e/ou CSE. Já as áreas construídas e trilhas devido a resolução espacial de origem das imagens multiespectrais, foram incluídas em outras classes.

Quando comparados os planos de informação que utilizaram as imagens normais, e imagens fusionadas para o ano base de 2017, para as classes  $CAD_{sarg}$ ,  $CSE_{sarg}$ ,  $AT_{CAD}$  e SEXP houve um aumento na proporção das áreas ocupadas por essas classes, e uma diminuição nas demais classes. Já para as imagens do ano base 2019, o aumento na proporção da área ocupada pela classe só foi mais evidente para as imagens fusionadas para as classes de  $CAD_{sarg}$  e  $CAD_{saren}$ . Na Tabela 14 a seguir, encontra-se descrito a proporção da área ocupada por cada classe e plano de informação mapeada em hectares (ha).

**Tabela 14** - Proporção da área em hectares (ha) ocupada pelas classes mapeadas.

Classe	Plano de informação								Média	%	D. Padrão	
	I	II	III	IV	IMFSV	IMFSVI	IMFSVII	IMFSVIII				
Ano base --2017	FA	205,19	260,54	215,90	209,39	238,38	226,59	221,45	214,67	224,01	0,45	18,03
	CAD <sub>sarg</sub>	6534,88	6597,85	6260,48	6093,74	7231,23	6694,33	7008,50	6750,34	6646,42	13,36	369,44
	CAD <sub>saren</sub>	16977,50	16991,62	17911,46	18040,73	16310,80	16976,53	16063,40	15967,51	16904,94	33,98	780,20
	CSE <sub>sarg</sub>	3088,29	3310,98	3312,90	2708,91	3714,14	3388,14	2912,86	3207,88	3205,51	6,44	307,23
	CSE <sub>saren</sub>	15054,16	14879,13	14886,75	14842,71	14945,80	14356,24	14938,81	15632,67	14942,03	30,03	348,39
	AT <sub>FA</sub>	699,85	1165,38	962,94	1149,95	867,35	950,12	1157,40	792,45	968,18	1,95	177,74
	AT <sub>CAD</sub>	3183,75	2980,78	2848,29	3186,66	3131,63	2931,66	3475,52	3091,29	3103,70	6,24	193,62
	SEXP	4009,39	3566,61	3354,18	3520,79	3313,70	4229,27	3975,02	4096,07	3758,13	7,55	358,58
MAG	-	-	-	-	-	-	-	-	-	-	0	-
Ano base - 2019	FA	240,61	213,27	231,30	252,01	241,85	242,77	205,13	259,57	235,81	0,47	18,53
	CAD <sub>sarg</sub>	6367,91	6758,99	6870,36	6687,37	7594,52	7323,47	7204,87	7519,17	7040,83	14,15	435,63
	CAD <sub>saren</sub>	17632,03	18014,45	17517,91	17844,79	17780,05	17954,69	18261,66	18198,16	17900,47	35,98	259,40
	CSE <sub>sarg</sub>	3343,15	2745,07	2875,93	2537,58	1886,40	3023,39	2652,95	2965,75	2753,78	5,53	429,16
	CSE <sub>saren</sub>	12835,93	13364,40	13190,40	13129,20	13843,97	13045,10	13364,26	12351,02	13140,53	26,41	434,71
	AT <sub>FA</sub>	1092,72	1238,24	1096,81	1091,82	1073,52	1115,06	1147,05	1005,26	1107,56	2,23	66,44
	AT <sub>CAD</sub>	3222,84	2831,66	3151,85	3392,56	2995,05	2866,70	3150,18	3054,45	3083,16	6,20	186,37
	SEXP	4896,54	4509,13	4586,58	4584,77	4215,27	4100,81	3584,24	4271,62	4343,62	8,73	397,77
MAG	121,06	77,49	231,24	232,45	122,13	79,19	182,00	127,40	146,62	0,29	61,79	

\*D. Padrão = Desvio Padrão.

\*IMFS – Imagens fusionadas.

% - Porcentual médio de áreas ocupadas por cada classe.

Fonte: Elaborado pelo autor (2021).

Na Tabela 14 também foi possível observar o percentual médio das áreas ocupadas por cada classe mapeada. Esses dados são importantes, já que revelam o nível de preservação ambiental da UC REBIO Serra Negra e seus entornos. Em uma análise mais ampla considerando toda área de estudo, o percentual médio das áreas cobertas por algum tipo de vegetação atingiram 92,45% e 90,97%, respectivamente para os anos de 2017 e 2019. Já o restante, que corresponderam a 7,55% (2017) e 9,03% (2019) são áreas de SEXP e/ou áreas com altos níveis de antropização e áreas de MAG. Na mesma via em que houve uma redução de 1,47% das áreas de vegetação, aumentou as áreas antropizadas, em virtude da construção de um grande barramento de água e limpeza de terreno próximos a Zona de Amortecimento da REBIO Serra Negra.

Analisando mais internamente a Zona de Amortecimento, observou-se que o percentual médio das áreas ocupadas pela vegetação atingiram 97,91% e 98,10%; e de solo exposto e áreas antropizadas 2,09% e 1,90%, respectivamente para os anos de 2017 e 2019. Porém, levando em consideração apenas a área do interior UC REBIO Serra Negra, para os dois anos mapeados (2017 e 2019), os resultados mostraram que 99% da UC é coberta por algum tipo de vegetação e menos de 1% são áreas de trilhas e de solo exposto. Esses resultados demonstram que a UC encontra-se em boas condições de preservação ambiental e vão de encontro com o parecer do Plano de Manejo da REBIO Serra Negra (BRASIL, 2011a).

Em uma comparação com mapeamentos anteriores para UC REBIO, os resultados foram bastante discrepantes em relação aos encontrados por esta pesquisa. Esses mapeamentos anteriores foram organizados pela Fundação Joaquim Nabuco (FUNDAJ) e pela Universidade Federal de Campina Grande (UFCG), em 2017, no âmbito do projeto do: “Mapeamento e Análise Espectro-Temporal das Unidades de Conservação de Proteção Integral da Administração Federal no Bioma Caatinga”, foram feitas duas cartas-imagens sobre o uso e ocupação da Terra para a REBIO Serra Negra. Neste mapeamento não foram incluídas as áreas da Zona de Amortecimento e regiões próximas. Foram utilizadas imagens do satélite LANDSAT 7 ETM<sup>+</sup> e 8 OLI, referentes aos anos base 2002 e 2016, e técnicas de fusão de imagens e métodos de classificação supervisionada para confecção dos mapas temáticos. Assim, foram mapeadas apenas quatro classes temáticas: fitofisionomia arbórea, fitofisionomia arbustiva, nuvem/sombra e solo exposto (FREIRE *et al.*, 2017).

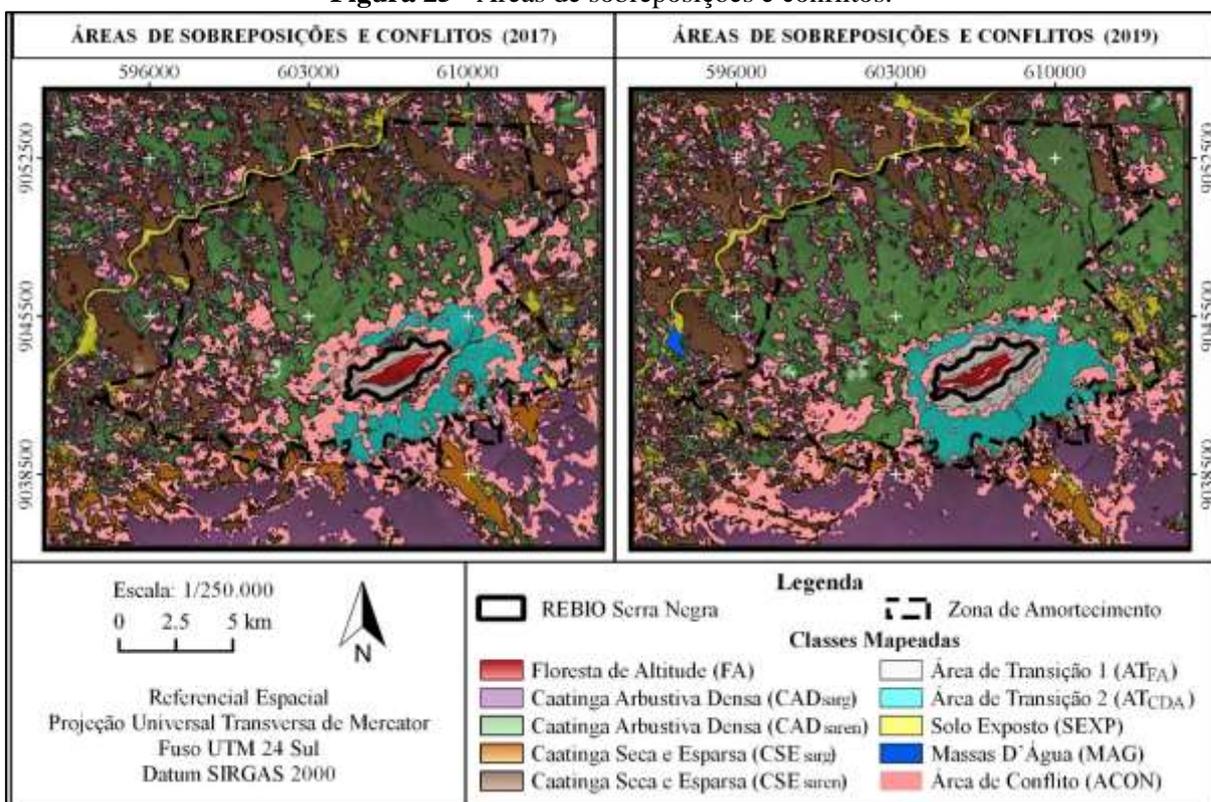
Dos resultados obtidos por esta pesquisa, identificou-se que 9,86% e 27,94% da área são de fitofisionomia arbórea, e fitofisionomia arbustiva corresponderam 19,09% e 46,78%; já áreas de solo exposto corresponderam 61,04% e 25,28%; e sombra e nuvem 10,01% e 0%, para

o os anos de 2002 e 2016, respectivamente (FREIRE *et al.*, 2017). Mesmo considerando as diferentes datas do mapeamento e as legendas adotadas, o destaque para esse mapeamento, e para as áreas ocupadas por solo exposto que correspondem 61,04% para o ano de 2002, e 25,28% para o ano de 2016, quando confrontados com os resultados obtidos por esta pesquisa são discrepantes. Dos resultados obtidos, a área média ocupada pela vegetação atinge 99% em ambos os anos analisados (2017 e 2019), considerando apenas a região interna da REBIO Serra Negra. Resultados semelhantes foram evidenciados a partir das análises do histórico de uso e ocupação da Terra pelo Google Earth, MAPBIOMAS e descrição do Plano de Manejo e no levantamento florísticos de Rodal e Nascimento (2002).

### 5.3 SOBREPOSIÇÃO DE CLASSES

Na análise de sobreposição considerando todos os planos de informação respectivamente para os anos bases de 2017 e 2019, mostrou que 57,75% e 62,89% das classes se sobrepõem, o restante ocupando 42,27% e 37,11% são áreas de conflitos entre uma, duas ou mais classes. Na **Figura 25** a seguir, mostra-se as áreas de sobreposição e conflitos, e na Tabela 15, a relação das áreas sobrepostas por classe.

**Figura 25** - Áreas de sobreposições e conflitos.



Fonte: Elaborado pelo autor (2021).

Tabela 15 - Percentual de áreas sobrepostas por classe

Classe	Planos de informação								Média Geral	
	I	II	III	IV	V	VI	VII	VIII		
Ano base --2017	FA	79,34	62,49	75,41	77,75	68,30	71,85	73,52	75,84	72,68
	CAD <sub>sarg</sub>	82,06	81,22	85,94	88,47	73,64	79,97	76,14	79,26	80,59
	CAD <sub>saren</sub>	52,90	52,85	50,07	49,70	55,12	52,90	55,99	56,34	53,13
	CSE <sub>sarg</sub>	69,04	63,67	63,63	80,61	55,82	62,00	73,95	66,05	66,11
	CSE <sub>saren</sub>	53,99	54,64	54,61	54,78	54,39	56,70	54,42	51,93	54,41
	AT <sub>FA</sub>	75,11	45,10	54,59	45,71	60,60	55,32	45,42	66,33	54,29
	AT <sub>CAD</sub>	58,68	62,67	65,59	58,62	59,65	63,72	53,75	60,43	60,19
	SEXP	40,81	46,02	49,01	46,63	49,63	38,64	41,17	39,93	43,61
	MAG	-	-	-	-	-	-	-	-	-
Ano base - 2019	FA	60,29	68,02	62,72	57,57	59,99	59,76	70,72	55,89	61,52
	CAD <sub>sarg</sub>	86,29	80,97	79,57	81,89	71,54	74,35	75,65	72,30	77,52
	CAD <sub>saren</sub>	68,21	66,73	68,66	67,38	67,63	66,95	65,80	66,04	67,16
	CSE <sub>sarg</sub>	39,60	49,76	47,12	54,63	78,82	44,45	51,81	45,46	49,58
	CSE <sub>saren</sub>	54,91	52,67	53,38	53,64	50,79	54,00	52,67	57,14	53,59
	AT <sub>FA</sub>	87,42	77,15	87,10	87,50	88,99	85,67	83,28	95,03	86,25
	AT <sub>CAD</sub>	70,20	79,90	71,78	66,69	75,54	78,92	71,82	74,07	73,38
	SEXP	36,53	39,73	39,04	39,06	42,55	43,77	50,23	41,98	41,27
	MAG	48,50	75,77	25,39	25,26	48,08	74,14	32,26	46,09	40,05

Fonte: Elaborado pelo autor (2021).

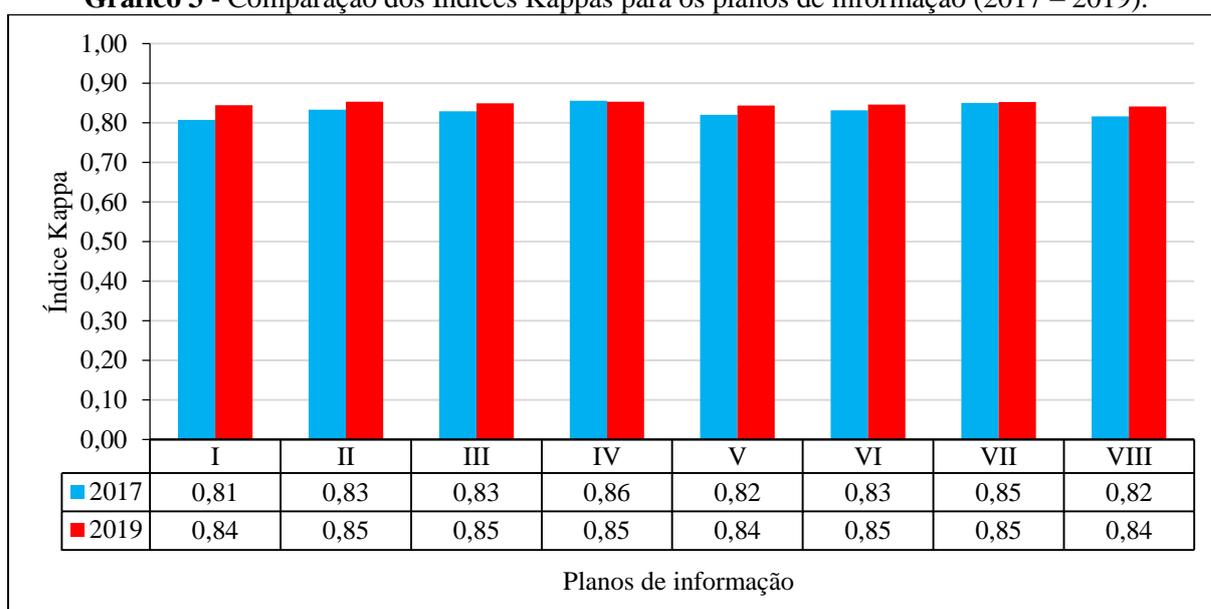
Em geral, os maiores conflitos entre as classes ocorreram para áreas de AT, CSE e SEXP para ambos os anos analisados. Foi observado também, para o ano base 2017, os planos de informação (I, II, III, IV), que utilizaram as imagens não fusionadas, e obtiveram maiores percentuais de sobreposição em relação aos planos de informação (V, VI, VII, VIII) com as imagens fusionadas. Para esse mesmo ano, as áreas que mais apresentaram conflitos foram CAD<sub>saren</sub>, CSE<sub>saren</sub>, AT<sub>FA</sub> e SEXP. Já para o ano base 2019, as classes de CSE, SEXP e MAG, apresentaram os menores percentuais de sobreposição, entre todos os planos de informação. Os planos de informação (V, VI, VII, VIII) com as imagens fusionadas, apresentaram maiores percentuais de sobreposição em relação aos planos de informação (I, II, III, IV) das imagens não fusionadas. Não foi avaliada a sobreposição de um ano em relação ao outro.

#### 5.4 AVALIAÇÕES DAS CLASSIFICAÇÕES

Com a utilização dos pontos de referência amostrados foi avaliado a qualidade da classificação de segmentação por meio da matriz de confusão, e dos respectivos índices de concordância Kappa, Kappa condicional (usuário e produtor), exatidão global e exatidões do usuário e produtor.

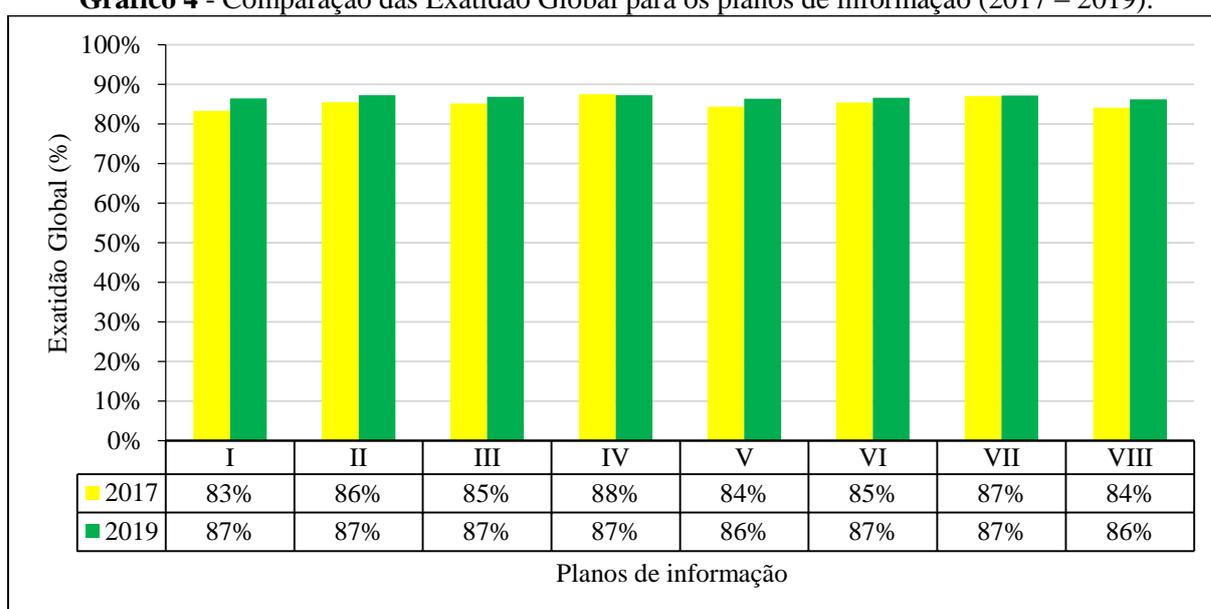
Os índices Kappa apresentaram bons resultados e valores semelhantes, o que demonstrou uma boa acurácia nas classificações realizadas utilizando os diferentes planos de informação. Para ambos os anos analisados (2017 - 2019), os índices Kappas variaram entre 0,81 a 0,86 (**Gráfico 3**). De acordo com a interpretação de Landis e Koch (1977), para este índice (**Tabela 11**), a concordância para todos os resultados obtidos foi quase perfeita. Na avaliação da exatidão global os resultados da classificação também foram superiores a 80% e com valores muito próximos (**Gráfico 4**).

**Gráfico 3** - Comparação dos Índices Kappas para os planos de informação (2017 – 2019).



Fonte: Elaborado pelo autor (2021).

**Gráfico 4** - Comparação das Exatidão Global para os planos de informação (2017 – 2019).



Fonte: Elaborado pelo autor (2021).

Não houve discrepância significativa entre os valores dos índices Kappa e exatidão global para avaliar quais planos de informação apresentaram os melhores resultados na classificação. Analisando os índices Kappa pelo teste de hipótese da estatística z para ao nível de significância a 5% ( $\alpha = 0,05$ ), quase não houve diferença significativa entre os resultados dos índices Kappas. Na **Tabela 16**, mostra o resultado do teste z, comparando os índices Kappas de um ano em relação ao outro (2017 vs 2019), para verificar se houve diferença significativa entre as épocas (data de aquisição) das imagens. Já nas **Tabela 17** e 18 mostra a estatística z comparando os Kappas entre um mesmo ano (2017 vs 2017 e 2019 vs 2019), para verificar se houve diferença estatística, levando em conta apenas os planos de informação (separadamente) entre cada ano.

**Tabela 16** -Teste z para significância entre os índices Kappas resultantes da classificação para as diferentes datas e planos de informação (2017 vs 2019).

Kappa		Planos de informação (2019)							
		I	II	III	VI	V	VI	VII	VIII
Planos de informação (2017)	I	-2,03*	-2,56*	-2,30*	-2,56*	-1,97*	-2,10*	-2,49*	-1,85*
	II	-0,65 <sup>ns</sup>	-1,18 <sup>ns</sup>	-0,92 <sup>ns</sup>	-1,18 <sup>ns</sup>	-0,58 <sup>ns</sup>	-0,72 <sup>ns</sup>	-1,11 <sup>ns</sup>	-0,47 <sup>ns</sup>
	III	-0,86 <sup>ns</sup>	-1,38 <sup>ns</sup>	-1,12 <sup>ns</sup>	-1,38 <sup>ns</sup>	-0,79 <sup>ns</sup>	-0,92 <sup>ns</sup>	-1,31 <sup>ns</sup>	-0,67 <sup>ns</sup>
	VI	0,65 <sup>ns</sup>	0,12 <sup>ns</sup>	0,38 <sup>ns</sup>	0,12 <sup>ns</sup>	0,72 <sup>ns</sup>	0,58 <sup>ns</sup>	0,19 <sup>ns</sup>	0,83 <sup>ns</sup>
	IMFSV	-1,36 <sup>ns</sup>	-1,88*	-1,62 <sup>ns</sup>	-1,88*	-1,29 <sup>ns</sup>	-1,42 <sup>ns</sup>	-1,81*	-1,17 <sup>ns</sup>
	IMFSVI	-0,73 <sup>ns</sup>	-1,26 <sup>ns</sup>	-1,00 <sup>ns</sup>	-1,26 <sup>ns</sup>	-0,66 <sup>ns</sup>	-0,80 <sup>ns</sup>	-1,19 <sup>ns</sup>	-0,54 <sup>ns</sup>
	IMFSVII	0,31 <sup>ns</sup>	-0,22 <sup>ns</sup>	0,04 <sup>ns</sup>	-0,22 <sup>ns</sup>	0,38 <sup>ns</sup>	0,24 <sup>ns</sup>	-0,15 <sup>ns</sup>	0,50 <sup>ns</sup>
	IMFSVIII	-1,54 <sup>ns</sup>	-2,07*	-1,81*	-2,07*	-1,48 <sup>ns</sup>	-1,61 <sup>ns</sup>	-2,00*	-1,36 <sup>ns</sup>

\*z estatístico = 1,96: significativa a 95% de probabilidade; ns = não significante.

\*IMFS- Imagens fusionadas.

**Tabela 17** - Teste z para significância entre os índices Kappas resultantes da classificação para os diferentes planos de informação (2017 vs 2017).

Kappa		Planos de informação (2017)							
		I	II	III	VI	IMFSV	IMFSVI	IMFSVII	IMFSVIII
Planos de informação (2017)	I	0							
	II	1,38 <sup>ns</sup>	0						
	III	1,18 <sup>ns</sup>	-0,20 <sup>ns</sup>	0					
	VI	2,68*	1,30 <sup>ns</sup>	1,50 <sup>ns</sup>	0				
	V	0,68 <sup>ns</sup>	-0,70 <sup>ns</sup>	-0,50 <sup>ns</sup>	-2,00*	0			
	VI	1,30 <sup>ns</sup>	-0,08 <sup>ns</sup>	0,12 <sup>ns</sup>	-1,38 <sup>ns</sup>	0,63 <sup>ns</sup>	0		
	VII	2,34*	0,96 <sup>ns</sup>	1,17 <sup>ns</sup>	-0,34 <sup>ns</sup>	1,66*	1,04 <sup>ns</sup>	0	
	VIII	0,49 <sup>ns</sup>	-0,89 <sup>ns</sup>	-0,69 <sup>ns</sup>	-2,19*	-0,19 <sup>ns</sup>	-0,81 <sup>ns</sup>	-1,85*	0

\*z estatístico = 1,96: significativa a 95% de probabilidade; ns = não significante.

\*IMFS- Imagens fusionadas.

Fonte: Elaborado pelo autor (2021).

**Tabela 18** - Teste z para significância entre os índices Kappa resultantes da classificação para os diferentes planos de informação (2019 vs 2019).

Kappa		Planos de informação (2019)							
		I	II	III	VI	IMFSV	IMFSVI	IMFSVII	IMFSVIII
Planos de informação (2019)	I	0							
	II	0,53 <sup>ns</sup>	0						
	III	0,27 <sup>ns</sup>	-0,26 <sup>ns</sup>	0					
	VI	0,53 <sup>ns</sup>	0,00 <sup>ns</sup>	0,26 <sup>ns</sup>	0				
	IMFSV	-0,07 <sup>ns</sup>	-0,60 <sup>ns</sup>	-0,34 <sup>ns</sup>	-0,60 <sup>ns</sup>	0			
	IMFSVI	0,07 <sup>ns</sup>	-0,46 <sup>ns</sup>	-0,20 <sup>ns</sup>	-0,46 <sup>ns</sup>	0,14 <sup>ns</sup>	0		
	IMFSVII	0,46 <sup>ns</sup>	-0,07 <sup>ns</sup>	0,19 <sup>ns</sup>	-0,07 <sup>ns</sup>	0,53 <sup>ns</sup>	0,39 <sup>ns</sup>	0	
	IMFSVIII	-0,19 <sup>ns</sup>	-0,72 <sup>ns</sup>	-0,46 <sup>ns</sup>	-0,72 <sup>ns</sup>	-0,12 <sup>ns</sup>	-0,26 <sup>ns</sup>	-0,65 <sup>ns</sup>	0

\*z estatístico = 1,96: significante a 95% de probabilidade; ns = não significante.

\*IMFS- Imagens fusionadas.

Fonte: Elaborado pelo autor (2021).

Quando comparados os índices Kappas de um ano em relação ao outro (2017 vs 2019) (Tabela 16), apenas 23,43% dos resultados apresentaram diferença significativa. O índice Kappa do plano de informação I, do ano base 2017 apresentou diferença significativa em relação aos outros planos de informação do ano base 2019. Já na comparação entre um mesmo ano, a classificação dos segmentos para o ano 2017 (Tabela 17), e para o ano 2019 (Tabela 18) houve diferença significativa de 25% e 0%, respectivamente para os resultados obtidos. Para os resultados que tiveram diferença significativa não repetiu um padrão específico para um determinado plano de informação. Somente com base nesses indicadores estatísticos não foi possível determinar qual dos anos, ou quais planos de informação apresentaram os resultados mais significativos. Essa pequenas variações entre os índices Kappas e exatidão global, demonstraram que a classificação por RNA pode ter desempenho diferente, conforme as particularidades de cada área a ser classificada, e dos planos de informação utilizados. Além disso, os resultados variam conforme os atributos utilizados e da complexidade de cada RNA gerada.

Na comparação entre os acertos específicos para cada classe, também não foi muito conclusiva, apresentando bastante semelhança. A comparação entre os acertos específicos para cada classe pode ser visualizada através das matrizes de confusão, índices do Kappas condicionais (usuário e produtor) e exatidões do usuário e produtor obtidos para todas as classificações (Tabela 19 a 34).

**Tabela 19** - Matriz de confusão da classificação do plano de informação I (NIR (8) - R(7) - G(6) - B(5) - PCA (8765) – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	48	0	0	0	0	4	0	0	0	52
	CAD <sub>saren</sub>	0	122	1	19	1	0	1	3	0	147
	CAD <sub>sarg</sub>	0	5	123	0	6	0	1	0	0	135
	CSE <sub>saren</sub>	0	5	1	128	1	0	0	18	0	153
	CSE <sub>sarg</sub>	0	2	1	3	90	0	0	1	0	97
	AT <sub>FA</sub>	4	19	0	0	0	69	21	0	0	113
	AT <sub>CDA</sub>	0	12	15	0	0	9	111	0	0	147
	SEXP	0	2	0	6	1	0	0	142	0	151
	MAG	0	0	0	0	0	3	0	2	0	5
<b>Total</b>	52	167	141	156	99	85	134	166	0	1000	
<b>Ep</b>	92%	73%	87%	82%	91%	81%	83%	86%	0%	83%	
<b>Eu</b>	92%	83%	91%	84%	93%	61%	76%	94%	0%		
<b>Ku</b>	0,92	0,80	0,90	0,81	0,92	0,57	0,72	0,93	0	-	
<b>Kp</b>	0,92	0,68	0,85	0,79	0,90	0,79	0,80	0,83	0	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 20** - Matriz de confusão da classificação do plano de informação II (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	52	0	0	0	0	0	0	0	0	52
	CAD <sub>saren</sub>	0	125	4	14	1	1	1	1	0	147
	CAD <sub>sarg</sub>	0	4	121	1	9	0	0	0	0	135
	CSE <sub>saren</sub>	0	6	0	128	2	0	0	17	0	153
	CSE <sub>sarg</sub>	0	0	1	1	93	0	0	2	0	97
	AT <sub>FA</sub>	7	8	0	0	0	94	4	0	0	113
	AT <sub>CDA</sub>	0	14	9	0	0	19	105	0	0	147
	SEXP	0	0	0	12	2	0	0	137	0	151
	MAG	0	3	0	0	0	2	0	0	0	5
<b>Total</b>	59	160	135	156	107	116	110	157	0	1000	
<b>Ep</b>	88%	78%	90%	82%	87%	81%	95%	87%	0%	86%	
<b>Eu</b>	100%	85%	90%	84%	96%	83%	71%	91%	0%		
<b>Ku</b>	1,00	0,82	0,88	0,81	0,95	0,81	0,68	0,89	0	-	
<b>Kp</b>	0,87	0,74	0,88	0,79	0,86	0,79	0,95	0,85	0	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 21** - Matriz de confusão da classificação do plano de informação III (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	50	0	0	0	0	2	0	0	0	52
	CAD <sub>saren</sub>	0	127	2	13	3	0	1	1	0	147
	CAD <sub>sarg</sub>	0	6	120	1	8	0	0	0	0	135
	CSE <sub>saren</sub>	0	4	0	139	0	0	0	10	0	153
	CSE <sub>sarg</sub>	0	1	4	3	89	0	0	0	0	97
	AT <sub>FA</sub>	7	6	0	0	0	77	23	0	0	113
	AT <sub>CDA</sub>	0	16	2	0	0	14	115	0	0	147
	SEXP	0	0	0	15	1	0	0	135	0	151
MAG	0	0	0	0	0	5	0	0	0	5	
<b>Total</b>		57	160	128	171	101	98	139	146	0	1000
<b>Ep</b>		88%	79%	94%	81%	88%	79%	83%	92%	0%	85%
<b>Eu</b>		96%	86%	89%	91%	92%	68%	78%	89%	0%	
<b>Ku</b>		0,96	0,84	0,87	0,89	0,91	0,65	0,75	0,88	0	-
<b>Kp</b>		0,87	0,76	0,93	0,78	0,87	0,76	0,80	0,91	0	-

Fonte: Elaborado pelo autor (2021).

**Tabela 22** - Matriz de confusão da classificação do plano de informação IV (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	49	0	0	0	0	3	0	0	0	52
	CAD <sub>saren</sub>	0	127	1	15	1	1	1	1	0	147
	CAD <sub>sarg</sub>	0	8	120	1	6	0	0	0	0	135
	CSE <sub>saren</sub>	0	4	0	134	1	0	0	14	0	153
	CSE <sub>sarg</sub>	0	1	3	2	91	0	0	0	0	97
	AT <sub>FA</sub>	1	5	0	0	0	103	4	0	0	113
	AT <sub>CDA</sub>	0	12	2	0	0	17	116	0	0	147
	SEXP	0	2	0	13	1	0	0	135	0	151
MAG	0	3	0	0	0	2	0	0	0	5	
<b>Total</b>		50	162	126	165	100	126	121	150	0	1000
<b>Ep</b>		98%	78%	95%	81%	91%	82%	96%	90%	0%	88%
<b>Eu</b>		94%	86%	89%	88%	94%	91%	79%	89%	0%	
<b>Ku</b>		0,94	0,84	0,87	0,85	0,93	0,90	0,76	0,88	0	-
<b>Kp</b>		0,98	0,75	0,94	0,78	0,90	0,79	0,95	0,88	0	-

Fonte: Elaborado pelo autor (2021).

**Tabela 23** - Matriz de confusão da classificação do plano de informação V (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	50	0	0	0	0	2	0	0	0	52
	CAD <sub>saren</sub>	0	111	9	20	3	1	2	1	0	147
	CAD <sub>sarg</sub>	0	5	124	0	5	1	0	0	0	135
	CSE <sub>saren</sub>	0	4	0	135	1	0	0	13	0	153
	CSE <sub>sarg</sub>	0	0	6	0	91	0	0	0	0	97
	AT <sub>FA</sub>	5	8	0	0	0	79	20	1	0	113
	AT <sub>CDA</sub>	0	16	14	0	0	4	113	0	0	147
	SEXP	0	1	0	9	0	0	0	141	0	151
	MAG	0	0	0	0	0	3	0	2	0	5
<b>Total</b>	55	145	153	164	100	90	135	158	0	1000	
<b>Ep</b>	91%	77%	81%	82%	91%	88%	84%	89%	0%	84%	
<b>Eu</b>	96%	76%	92%	88%	94%	70%	77%	93%	0%		
<b>Ku</b>	0,96	0,71	0,90	0,86	0,93	0,67	0,73	0,92	0	-	
<b>Kp</b>	0,90	0,73	0,78	0,79	0,90	0,86	0,81	0,87	0	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 24** - Matriz de confusão da classificação do plano de informação VI (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF – 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	49	0	0	0	0	3	0	0	0	52
	CAD <sub>saren</sub>	0	122	8	12	3	0	1	1	0	147
	CAD <sub>sarg</sub>	0	11	116	1	7	0	0	0	0	135
	CSE <sub>saren</sub>	0	5	0	127	1	0	0	20	0	153
	CSE <sub>sarg</sub>	0	0	1	3	92	0	0	1	0	97
	AT <sub>FA</sub>	3	3	0	0	0	91	16	0	0	113
	AT <sub>CDA</sub>	0	15	10	0	0	8	113	1	0	147
	SEXP	0	0	0	7	0	0	0	144	0	151
	MAG	0	2	0	0	0	0	0	3	0	5
<b>Total</b>	52	158	135	150	103	102	130	170	0	1000	
<b>Ep</b>	94%	77%	86%	85%	89%	89%	87%	85%	0%	85%	
<b>Eu</b>	94%	83%	86%	83%	95%	81%	77%	95%	0%		
<b>Ku</b>	0,94	0,80	0,84	0,80	0,94	0,78	0,73	0,94	0	-	
<b>Kp</b>	0,94	0,73	0,84	0,82	0,88	0,88	0,85	0,82	0	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 25** - Matriz de confusão da classificação do plano de informação VII (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	50	0	0	0	0	2	0	0	0	52
	CAD <sub>saren</sub>	0	110	6	23	2	2	2	2	0	147
	CAD <sub>sarg</sub>	0	8	121	0	5	0	1	0	0	135
	CSE <sub>saren</sub>	0	6	0	132	1	0	0	14	0	153
	CSE <sub>sarg</sub>	0	0	5	1	91	0	0	0	0	97
	AT <sub>FA</sub>	2	2	0	0	0	98	11	0	0	113
	AT <sub>CDA</sub>	0	8	0	0	0	11	128	0	0	147
	SEXP	0	0	0	11	0	0	0	140	0	151
	MAG	0	0	0	0	0	5	0	0	0	5
<b>Total</b>		52	134	132	167	99	118	142	156	0	1000
<b>Ep</b>		96%	82%	92%	79%	92%	83%	90%	90%	0%	87%
<b>Eu</b>		96%	75%	90%	86%	94%	87%	87%	93%	0%	
<b>Ku</b>		0,96	0,71	0,88	0,84	0,93	0,85	0,85	0,91	0	-
<b>Kp</b>		0,96	0,79	0,90	0,75	0,91	0,81	0,88	0,88	0	-

Fonte: Elaborado pelo autor (2021).

**Tabela 26** - Matriz de confusão da classificação do plano de informação VIII (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2017).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	49	0	0	0	0	3	0	0	0	52
	CAD <sub>saren</sub>	0	113	5	23	4	0	0	2	0	147
	CAD <sub>sarg</sub>	0	9	116	0	10	0	0	0	0	135
	CSE <sub>saren</sub>	0	6	0	126	1	0	0	20	0	153
	CSE <sub>sarg</sub>	0	0	2	1	94	0	0	0	0	97
	AT <sub>FA</sub>	2	6	0	1	0	76	28	0	0	113
	AT <sub>CDA</sub>	0	9	9	0	0	6	123	0	0	147
	SEXP	0	0	0	7	0	0	0	144	0	151
	MAG	0	0	0	0	0	5	0	0	0	5
<b>Total</b>		51	143	132	158	109	90	151	166	0	1000
<b>Ep</b>		96%	79%	88%	80%	86%	84%	81%	87%	0%	84%
<b>Eu</b>		94%	77%	86%	82%	97%	67%	84%	95%	0%	
<b>Ku</b>		0,94	0,73	0,84	0,79	0,97	0,64	0,81	0,94	0	-
<b>Kp</b>		0,96	0,75	0,86	0,76	0,85	0,82	0,78	0,84	0	-

Fonte: Elaborado pelo autor (2021).

**Tabela 27** - Matriz de confusão da classificação do plano de informação I (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	52	0	0	0	0	0	0	0	0	52
	CAD <sub>saren</sub>	0	130	1	14	3	0	0	1	0	149
	CAD <sub>sarg</sub>	0	0	116	3	12	0	2	0	0	133
	CSE <sub>saren</sub>	0	14	1	115	9	0	0	12	0	151
	CSE <sub>sarg</sub>	0	2	15	11	65	0	0	1	0	94
	AT <sub>FA</sub>	2	0	0	0	0	108	0	1	0	111
	AT <sub>CDA</sub>	0	9	2	0	0	5	131	0	0	147
	SEXP	0	2	0	4	2	0	0	140	0	148
	MAG	0	0	0	0	0	0	0	7	8	15
<b>Total</b>	54	157	135	147	91	113	133	162	8	1000	
<b>Eu</b>	96%	83%	86%	78%	71%	96%	98%	86%	100%	87%	
<b>Ep</b>	100%	87%	87%	76%	69%	97%	89%	95%	53%		
<b>Ku</b>	1	0,85	0,85	0,72	0,66	0,97	0,87	0,94	0,53	-	
<b>Kp</b>	0,96	0,80	0,84	0,74	0,68	0,95	0,98	0,84	1	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 28** - Matriz de confusão da classificação do plano de informação II (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	50	0	0	0	0	2	0	0	0	52
	CAD <sub>saren</sub>	0	129	0	17	2	0	0	1	0	149
	CAD <sub>sarg</sub>	0	0	123	5	4	0	1	0	0	133
	CSE <sub>saren</sub>	0	13	0	124	4	0	0	10	0	151
	CSE <sub>sarg</sub>	0	1	13	10	70	0	0	0	0	94
	AT <sub>FA</sub>	2	0	0	0	0	109	0	0	0	111
	AT <sub>CDA</sub>	0	5	4	0	0	15	122	1	0	147
	SEXP	0	1	0	8	1	0	0	138	0	148
	MAG	0	0	0	0	0	0	0	7	8	15
<b>Total</b>	52	149	140	164	81	126	123	157	8	1000	
<b>Eu</b>	96%	87%	88%	76%	86%	87%	99%	88%	100%	87%	
<b>Ep</b>	96%	87%	92%	82%	74%	98%	83%	93%	53%		
<b>Ku</b>	0,96	0,84	0,91	0,79	0,72	0,98	0,81	0,92	0,53	-	
<b>Kp</b>	0,96	0,84	0,86	0,71	0,85	0,85	0,99	0,86	1	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 29** - Matriz de confusão da classificação do plano de informação III (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	52	0	0	0	0	0	0	0	0	52
	CAD <sub>saren</sub>	0	126	2	16	3	0	0	2	0	149
	CAD <sub>sarg</sub>	0	2	123	2	4	0	2	0	0	133
	CSE <sub>saren</sub>	0	13	1	111	6	0	0	19	1	151
	CSE <sub>sarg</sub>	0	0	9	10	73	0	0	1	1	94
	AT <sub>FA</sub>	1	0	0	0	0	109	1	0	0	111
	AT <sub>CDA</sub>	0	7	2	0	0	8	130	0	0	147
	SEXP	0	1	0	4	4	0	0	138	1	148
	MAG	0	0	0	1	0	0	0	7	7	15
<b>Total</b>	53	149	137	144	90	117	133	167	10	1000	
<b>Eu</b>	98%	85%	90%	77%	81%	93%	98%	83%	70%	87%	
<b>Ep</b>	100%	85%	92%	74%	78%	98%	88%	93%	47%		
<b>Ku</b>	1	0,82	0,91	0,69	0,75	0,98	0,87	0,92	0,46	-	
<b>Kp</b>	0,98	0,82	0,88	0,73	0,79	0,92	0,97	0,80	0,70	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 30** - Matriz de confusão da classificação do plano de informação IV (NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	50	0	0	0	0	2	0	0	0	52
	CAD <sub>saren</sub>	0	126	0	17	3	0	0	2	1	149
	CAD <sub>sarg</sub>	0	0	125	0	6	0	2	0	0	133
	CSE <sub>saren</sub>	0	11	1	117	8	0	0	14	0	151
	CSE <sub>sarg</sub>	0	2	11	16	64	0	0	1	0	94
	AT <sub>FA</sub>	4	0	0	0	0	107	0	0	0	111
	AT <sub>CDA</sub>	0	6	2	0	0	4	135	0	0	147
	SEXP	0	0	0	7	0	0	0	141	0	148
	MAG	0	0	0	0	0	0	0	7	8	15
<b>Total</b>	54	145	139	157	81	113	137	165	9	1000	
<b>Eu</b>	93%	87%	90%	75%	79%	95%	99%	85%	89%	87%	
<b>Ep</b>	96%	85%	94%	77%	68%	96%	92%	95%	53%		
<b>Ku</b>	0,96	0,82	0,93	0,73	0,65	0,96	0,91	0,94	0,53	-	
<b>Kp</b>	0,92	0,85	0,88	0,70	0,77	0,94	0,98	0,83	0,89	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 31** - Matriz de confusão da classificação do plano de informação V (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	49	0	0	0	0	3	0	0	0	52
	CAD <sub>saren</sub>	0	128	2	14	4	0	0	1	0	149
	CAD <sub>sarg</sub>	0	0	129	1	3	0	0	0	0	133
	CSE <sub>saren</sub>	0	14	2	120	6	0	0	9	0	151
	CSE <sub>sarg</sub>	0	4	26	17	46	0	1	0	0	94
	AT <sub>FA</sub>	3	0	0	0	0	107	1	0	0	111
	AT <sub>CDA</sub>	0	7	0	0	0	5	134	0	1	147
	SEXP	0	4	0	2	3	0	0	139	0	148
MAG	0	0	0	0	0	0	0	3	12	15	
<b>Total</b>		52	157	159	154	62	115	136	152	13	1000
<b>Eu</b>		94%	82%	81%	78%	74%	93%	99%	91%	92%	86%
<b>Ep</b>		94%	86%	97%	79%	49%	96%	91%	94%	80%	
<b>Ku</b>		0,94	0,83	0,96	0,76	0,46	0,96	0,90	0,93	0,80	-
<b>Kp</b>		0,94	0,78	0,78	0,74	0,72	0,92	0,98	0,90	0,92	-

Fonte: Elaborado pelo autor (2021).

**Tabela 32** - Matriz de confusão da classificação do plano de informação VI (<sup>IMFS</sup>NIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	48	0	0	0	0	4	0	0	0	52
	CAD <sub>saren</sub>	0	127	5	13	2	0	0	2	0	149
	CAD <sub>sarg</sub>	0	0	124	4	5	0	0	0	0	133
	CSE <sub>saren</sub>	0	14	2	122	8	0	0	5	0	151
	CSE <sub>sarg</sub>	0	2	20	7	62	0	0	3	0	94
	AT <sub>FA</sub>	5	0	0	0	0	106	0	0	0	111
	AT <sub>CDA</sub>	0	8	0	0	0	10	129	0	0	147
	SEXP	0	2	0	8	0	0	0	138	0	148
MAG	0	5	0	0	0	0	0	0	10	15	
<b>Total</b>		54	163	149	153	81	119	129	148	4	1000
<b>Eu</b>		89%	78%	83%	80%	77%	89%	100%	93%	250%	87%
<b>Ep</b>		92%	85%	93%	81%	66%	95%	88%	93%	67%	
<b>Ku</b>		0,92	0,82	0,92	0,77	0,63	0,95	0,86	0,92	0,67	-
<b>Kp</b>		0,88	0,74	0,81	0,76	0,74	0,88	1	0,92	2,52	-

Fonte: Elaborado pelo autor (2021).

**Tabela 33** - Matriz de confusão da classificação do plano de informação VII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - MDA - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	43	0	0	0	0	9	0	0	0	52
	CAD <sub>saren</sub>	0	128	3	13	5	0	0	0	0	149
	CAD <sub>sarg</sub>	0	0	124	5	4	0	0	0	0	133
	CSE <sub>saren</sub>	0	11	3	125	3	0	0	9	0	151
	CSE <sub>sarg</sub>	0	1	13	12	66	0	0	2	0	94
	AT <sub>FA</sub>	1	0	0	0	0	108	2	0	0	111
	AT <sub>CDA</sub>	0	6	0	0	0	6	135	0	0	147
	SEXP	0	4	0	11	3	0	0	130	0	148
	MAG	0	0	0	0	0	0	0	2	13	15
<b>Total</b>	44	150	143	166	81	123	137	143	13	1000	
<b>Eu</b>	98%	85%	87%	75%	81%	88%	99%	91%	100%	87%	
<b>Ep</b>	83%	86%	93%	83%	70%	97%	92%	88%	87%		
<b>Ku</b>	0,82	0,83	0,92	0,79	0,68	0,97	0,91	0,86	0,86	-	
<b>Kp</b>	0,98	0,83	0,85	0,71	0,80	0,86	0,98	0,89	1	-	

Fonte: Elaborado pelo autor (2021).

**Tabela 34** - Matriz de confusão da classificação do plano de informação VIII (IMFSNIR(8) - R(7) - G(6) - B(5) - PCA (8765) - NDVI - SAVI - IAF - MDA - 2019).

Classes		Amostras de referência									
		FA	CAD <sub>saren</sub>	CAD <sub>sarg</sub>	CSE <sub>saren</sub>	CSE <sub>sarg</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP	MAG	Total
Classificadas	FA	51	0	0	0	0	1	0	0	0	52
	CAD <sub>saren</sub>	0	120	5	17	5	0	0	2	0	149
	CAD <sub>sarg</sub>	0	0	123	0	10	0	0	0	0	133
	CSE <sub>saren</sub>	0	16	2	113	9	0	0	11	0	151
	CSE <sub>sarg</sub>	0	2	17	12	61	0	0	2	0	94
	AT <sub>FA</sub>	3	0	0	0	0	107	1	0	0	111
	AT <sub>CDA</sub>	0	6	0	0	0	3	138	0	0	147
	SEXP	0	4	0	6	3	0	0	135	0	148
	MAG	0	0	0	1	0	0	0	0	14	15
<b>Total</b>	54	148	147	149	88	111	139	150	14	1000	
<b>Eu</b>	94%	81%	84%	76%	69%	96%	99%	90%	100%	86%	
<b>Ep</b>	98%	81%	92%	75%	65%	96%	94%	91%	93%		
<b>Ku</b>	0,98	0,77	0,91	0,70	0,62	0,96	0,93	0,90	0,93	-	
<b>Kp</b>	0,94	0,78	0,81	0,72	0,66	0,96	0,99	0,88	1	-	

Fonte: Elaborado pelo autor (2021).

Em geral, os menores acertos foram para a classe de massas d'água (MAG), seguidos pelos acertos das áreas de CSE e CAD. O baixo acerto para classe de MAG está associado principalmente pela falta de áreas amostrais, principalmente para o ano base de 2017, onde as

imagens foram adquiridas já ao final do período seco. A sazonalidade teve influência sobre os acertos para as áreas de MAG, CAD e CSE, que são mais influenciadas pela dinâmica da vegetação e pelas condições climáticas. Os maiores acertos da exatidão do usuário e produto e Kappas condicionais foram para as áreas de FA e áreas de transição ( $AT_{FA}$  e  $AT_{CAD}$ ). Não houve grandes diferenças entre os acertos entre classes quando comparadas entre os anos de 2017 e 2019.

Com base na análise da matriz de confusão e dos respectivos índices de concordância Kappa, Kappa condicional (usuário e produtor), exatidão global e exatidões do usuário e produtor, não houve discrepância significativa entre os resultados de classificações considerando os diferentes planos de informação e épocas. Portanto, não foi possível definir quais resultados obtiveram o melhor desempenho apenas baseando nestas análises. Em geral, todos os resultados se mostraram satisfatórios quanto à análise estatística, com os indicadores dos índices de concordância Kappa e Kappa condicional, sendo superiores aos encontrados por Viana (2012), Souza (2015) e Sothe (2015), para classificações de fitofisionomias.

Viana (2012), objetivou de avaliar o potencial das imagens ALOS/PALSAR, banda L, para discriminar fitofisionomias do bioma Cerrado, localizadas no Parque Nacional da Chapada dos Veadeiros. Esse autor supracitado utilizou técnicas de segmentação baseadas em crescimento de regiões homogêneas, e classificação por: ISOSEG (*Iterative Self-Organization Data Analysis Technique*); MAXVER-ICM (Máxima Verossimilhança - *Iterated Conditional Mode*); e SVM (*Support Vector Machine*). Obteve baixo desempenho para os indicadores de concordância, sendo que as exatidões globais variaram entre 75% a 78% e índices Kappas entre 0,71 a 0,76. Segundo esse mesmo autor, o baixo desempenho das classificações para discriminar fitofisionomias deve ser considerado com certa ressalva por causa da complexidade das composições das vegetações.

Souza (2015), também obteve desempenho baixo para os índices Kappas (0,35 e 0,44) e de acurácia do produtor e do usuário (entre 8% a 70%), para classificação de fitofisionomias do bioma Mata Atlântica, no estado de São Paulo, no município de Santos, utilizando imagens do satélite World View 2. Já Sothe (2015), avaliou três metodologias utilizando técnicas de mineração de dados com algoritmos de árvore de decisão, para classificar estádios sucessionais de florestas secundárias da Floresta Ombrófila Mista (FOM) em três áreas-teste situadas na região serrana de Santa Catarina (SC). Ela utilizou três bandas do visível (0,38 - 0,70  $\mu\text{m}$ ), três bandas no infravermelho próximo (0,76 - 0,78  $\mu\text{m}$ ) e o MDS, com alta resolução espacial (0,39 m) obtidas no levantamento aerofotogramétrico de SC. Obteve índices Kappas variando entre

0,6 e 0,89, e conclui que apenas com base nesses indicadores de concordância não teria como indicar a melhor metodologia utilizada.

## 5.5 AVALIAÇÕES E DISCUSSÕES GERAIS

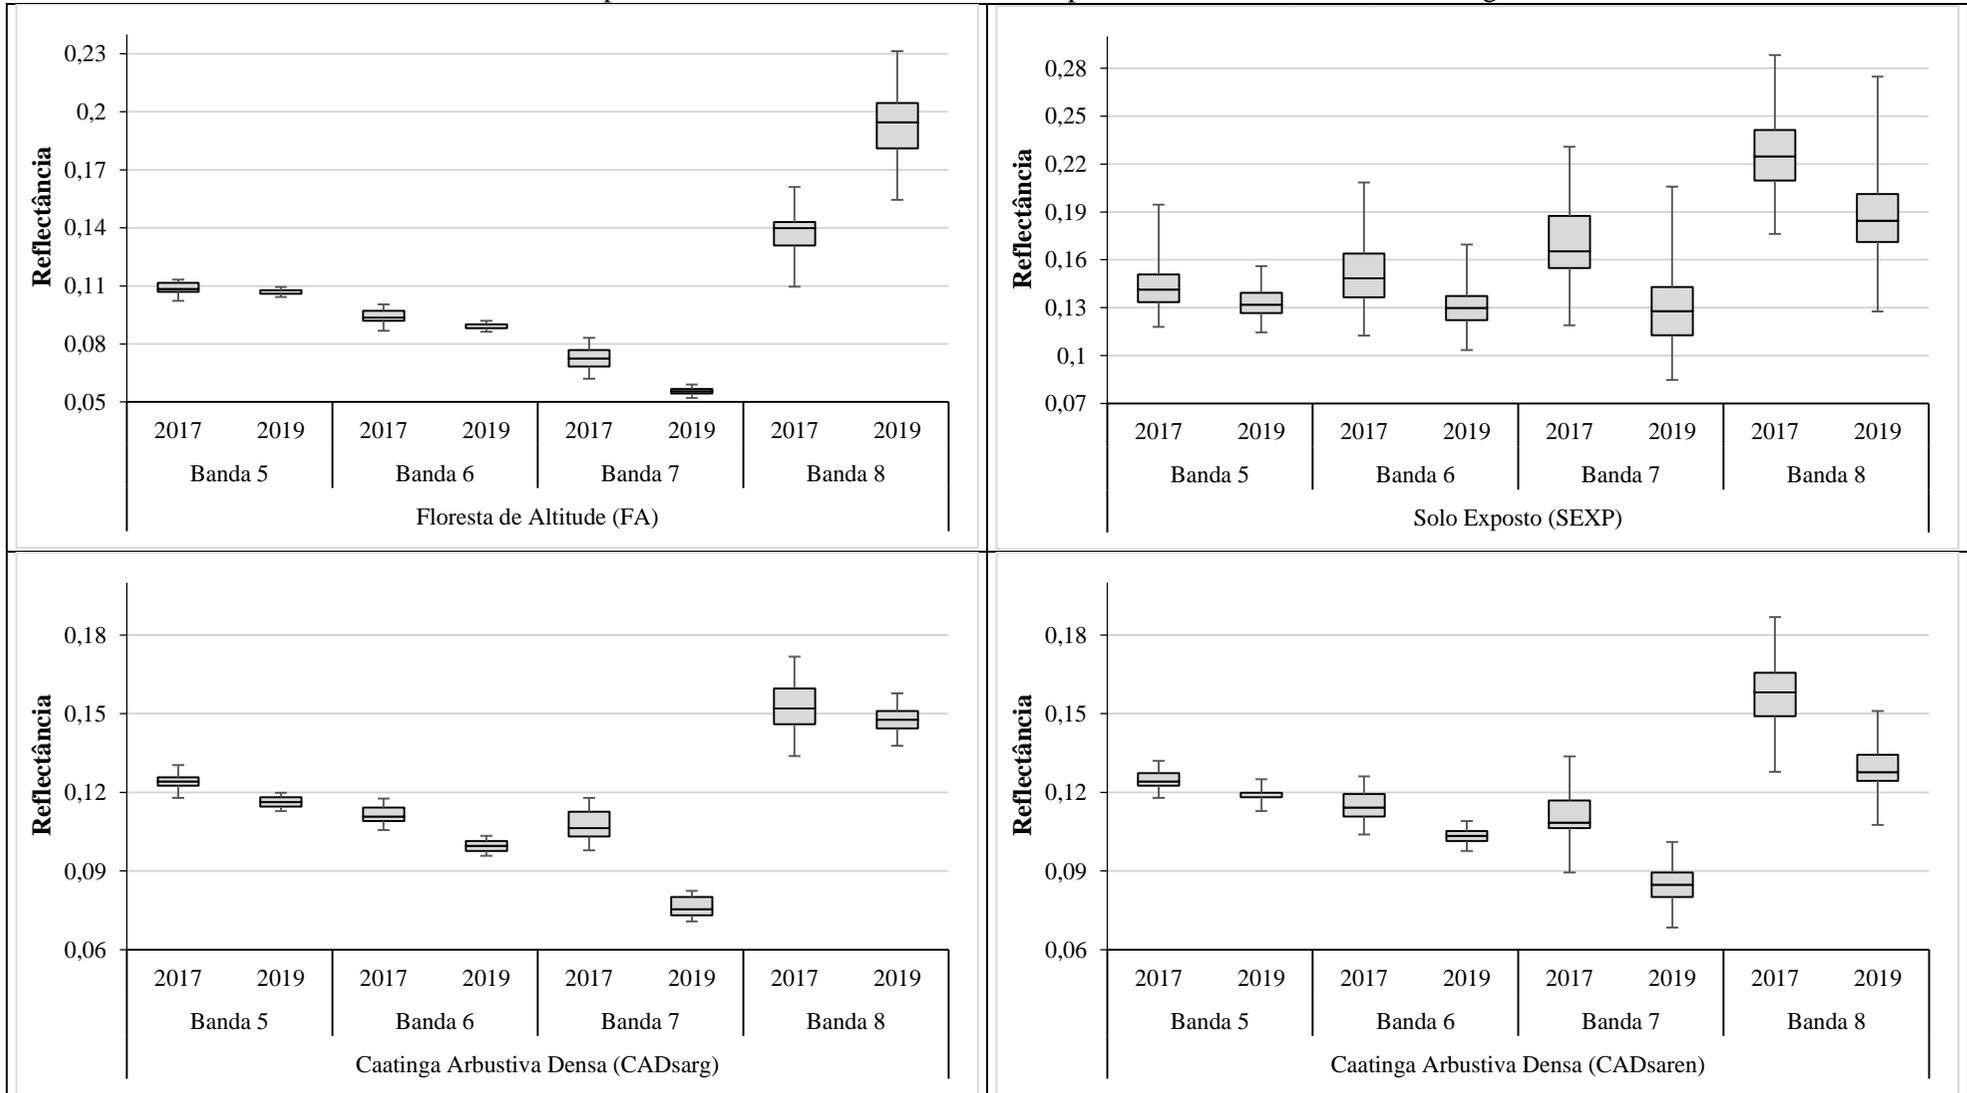
Nesta seção foram feitos algumas análises com intuito de verificar influências das bandas multiespectrais, índices espectrais e MDA para a discriminação das classes, bem como os métodos adotados para segmentação e classificação.

### 5.5.1 *Bandas multiespectrais*

Para avaliar a influência das bandas multiespectrais e índices espectrais (NDVI, SAVI e IAF), foi elaborada os testes de significância de Soma de Postos de Wilcoxon (Mann-Whitney) e análise descritiva sobre os principais atributos utilizados no processo de segmentação e classificação dos planos de informação. Sendo estas avaliações elaboradas apenas para as bandas multiespectrais não fusionadas, que foram utilizadas para elaboração dos índices espectrais.

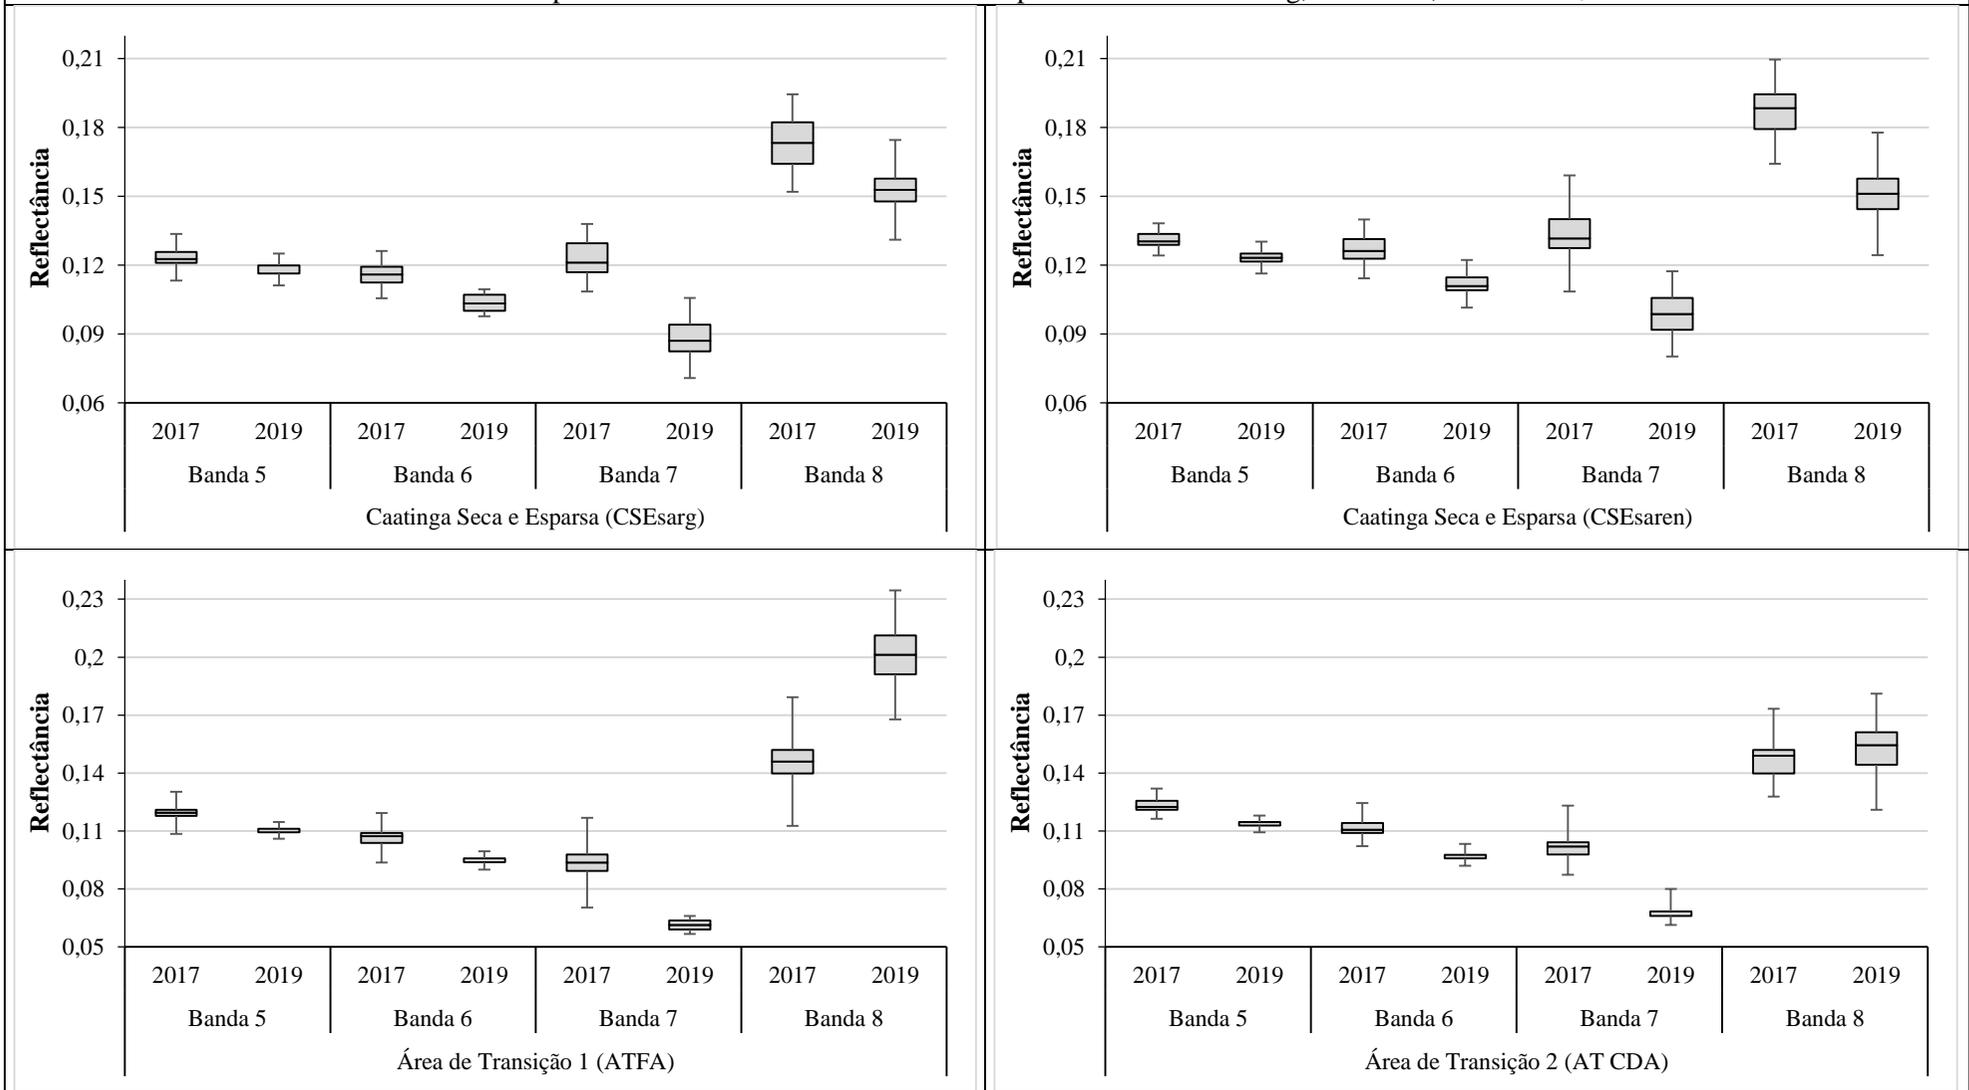
Os valores de reflectância foram semelhantes aos reportadas por Pinto *et al.* (2016) e Martins *et al.* (2018), para imagens multiespectrais do satélite CBERS-4 câmera MUX. Nas análises das bandas multiespectrais (B8/B7/B6/B5) do satélite CBERS-4 câmera MUX, constatou que as diferentes classes de uso e cobertura da Terra apresentaram algumas semelhança no nível de cinza. Analisando os intervalos espectrais, nota se que em uma classificação pautada apenas nas características espectrais dos objetos tenderia a apresentar inconsistências entre classes devido a semelhança dos perfis espectrais. Evidenciando-se a importância de também serem considerados os atributos referentes à textura e à alturas dos objetos analisados para o processo de classificação. Nos **Gráfico 5 a 7**), a seguir, encontram-se apresentados os intervalos de reflectância, elaborados com base nas amostras de referência.

**Gráfico 5 - Comparativos dos intervalos de reflectância para classes de FA, SEXP, CADsarg e CADsaren.**

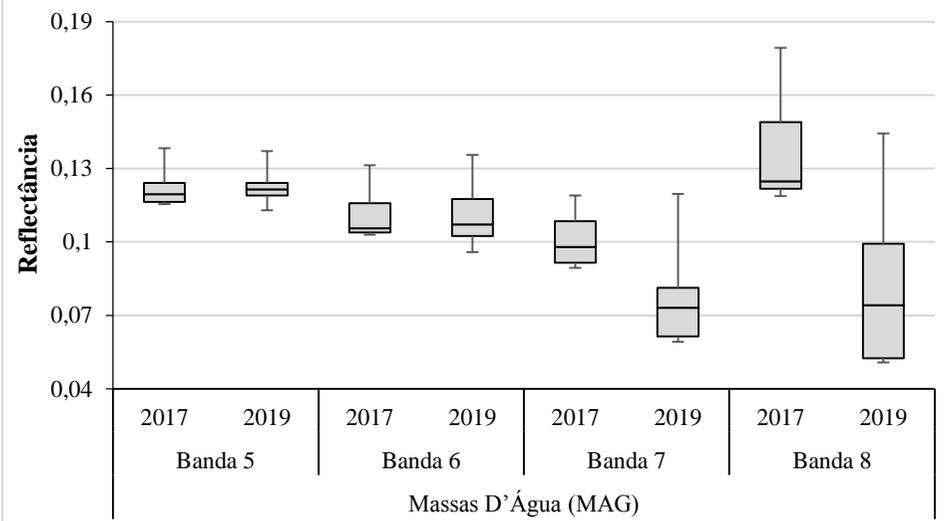


Fonte: Elaborado pelo autor (2021).

**Gráfico 6 - Comparativos dos intervalos de reflectância para classes de CSEsarg, CSEsaren, AT<sub>FA</sub> e AT<sub>CAD</sub>.**



Fonte: Elaborado pelo autor (2021).

**Gráfico 7 - Comparativos dos intervalos de reflectância para classes de MAG.**

Fonte: Elaborado pelo autor (2021).

Com base nos gráficos anteriores pode-se observar que os valores de reflectância são muito semelhantes, e apresentam um comportamento parecido entre as bandas multiespectrais. Nota-se algumas variações nos valores de reflectância por classe, e também entre os períodos analisados (2017 e 2019). A reflectância das imagens do ano base 2019, referentes ao final do período chuvoso apresentaram maiores valores de reflectância, quando comparadas com as imagens de reflectância do ano base 2017, referentes ao final do período seco. Observou-se que a reflectância para áreas de FA, CAD, CSE e AT apresentam comportamento semelhantes para as bandas do canal azul (B5) e verde (B6), e maiores diferença na resposta espectral na região do vermelho (B7) e do infravermelho próximo (B8). Já para áreas de SEXP e MAG foi obtido as maiores variações entre os valores máximos e mínimos de reflectância.

Na comparação gráfica, observou-se que as classes apresentaram semelhança no nível de reflectância, indicando que a classificação baseada apenas no comportamento espectral, poderia apresentar dificuldades para discriminação da mesma. Porém, pelo Teste de Soma de Postos de Wilcoxon (Mann-Whitney), elaborado com base nas amostras de referência, notou-se que boa parte das classes apresentaram diferença significativa entre si, com poucas exceções. Os testes de significância encontrassem nas **Tabela 35** a 38, para as imagens base do dia 23 de janeiro de 2017, e nas 39 a 42, e para as imagens base do dia 20 de agosto de 2019.

**Tabela 35** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 5(B) do ano base 2017 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0534 <sup>ns</sup>	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0681 <sup>ns</sup>	,0008	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,4034 <sup>ns</sup>	,0077	,2223 <sup>ns</sup>	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0002	,1801 <sup>ns</sup>	,1406 <sup>ns</sup>	,3556 <sup>ns</sup>	,0149	,8544 <sup>ns</sup>	,2133 <sup>ns</sup>	,0019

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 36** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 6(G) do ano base 2017 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,4289 <sup>ns</sup>	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,9216 <sup>ns</sup>	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0002	,3780 <sup>ns</sup>	,1735 <sup>ns</sup>	,1496 <sup>ns</sup>	,0073	,7412 <sup>ns</sup>	,4614 <sup>ns</sup>	,0004

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 37** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 7(R) do ano base 2017 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0023	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0002	,1660 <sup>ns</sup>	,0779 <sup>ns</sup>	,0012	,00018	,2267 <sup>ns</sup>	,7510 <sup>ns</sup>	,0002

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 38** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 8(NIR) do ano base 2017 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0107	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,6424 <sup>ns</sup>	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,4694 <sup>ns</sup>	,0889 <sup>ns</sup>	,0558 <sup>ns</sup>	,0054	,0006	,2270 <sup>ns</sup>	,1753 <sup>ns</sup>	,0002

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 39** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 5(B) do ano base 2019 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0011	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,0000	,0092	,0014	,0823 <sup>ns</sup>	,0000	,0000	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 40** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 6(G) do ano base 2019 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,8150 <sup>ns</sup>	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,0000	,0190	,0460	,0280	,0000	,0000	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 41** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 7(R) do ano base 2019 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0003	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0000	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,1177 <sup>ns</sup>	,0013	,0003	,0000	,0000	,2227 <sup>ns</sup>	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 42** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para banda 8(NIR) do ano base 2019 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0007	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,2499 <sup>ns</sup>	,0000	,0816 <sup>ns</sup>	-	-	-	-
AT <sub>FA</sub>	,0150	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0006	,0000	,6402 <sup>ns</sup>	,0199	,0000	-	-
SEXP	,0371	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,0000	,0000	,0000	,0000	,0000	,0000	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

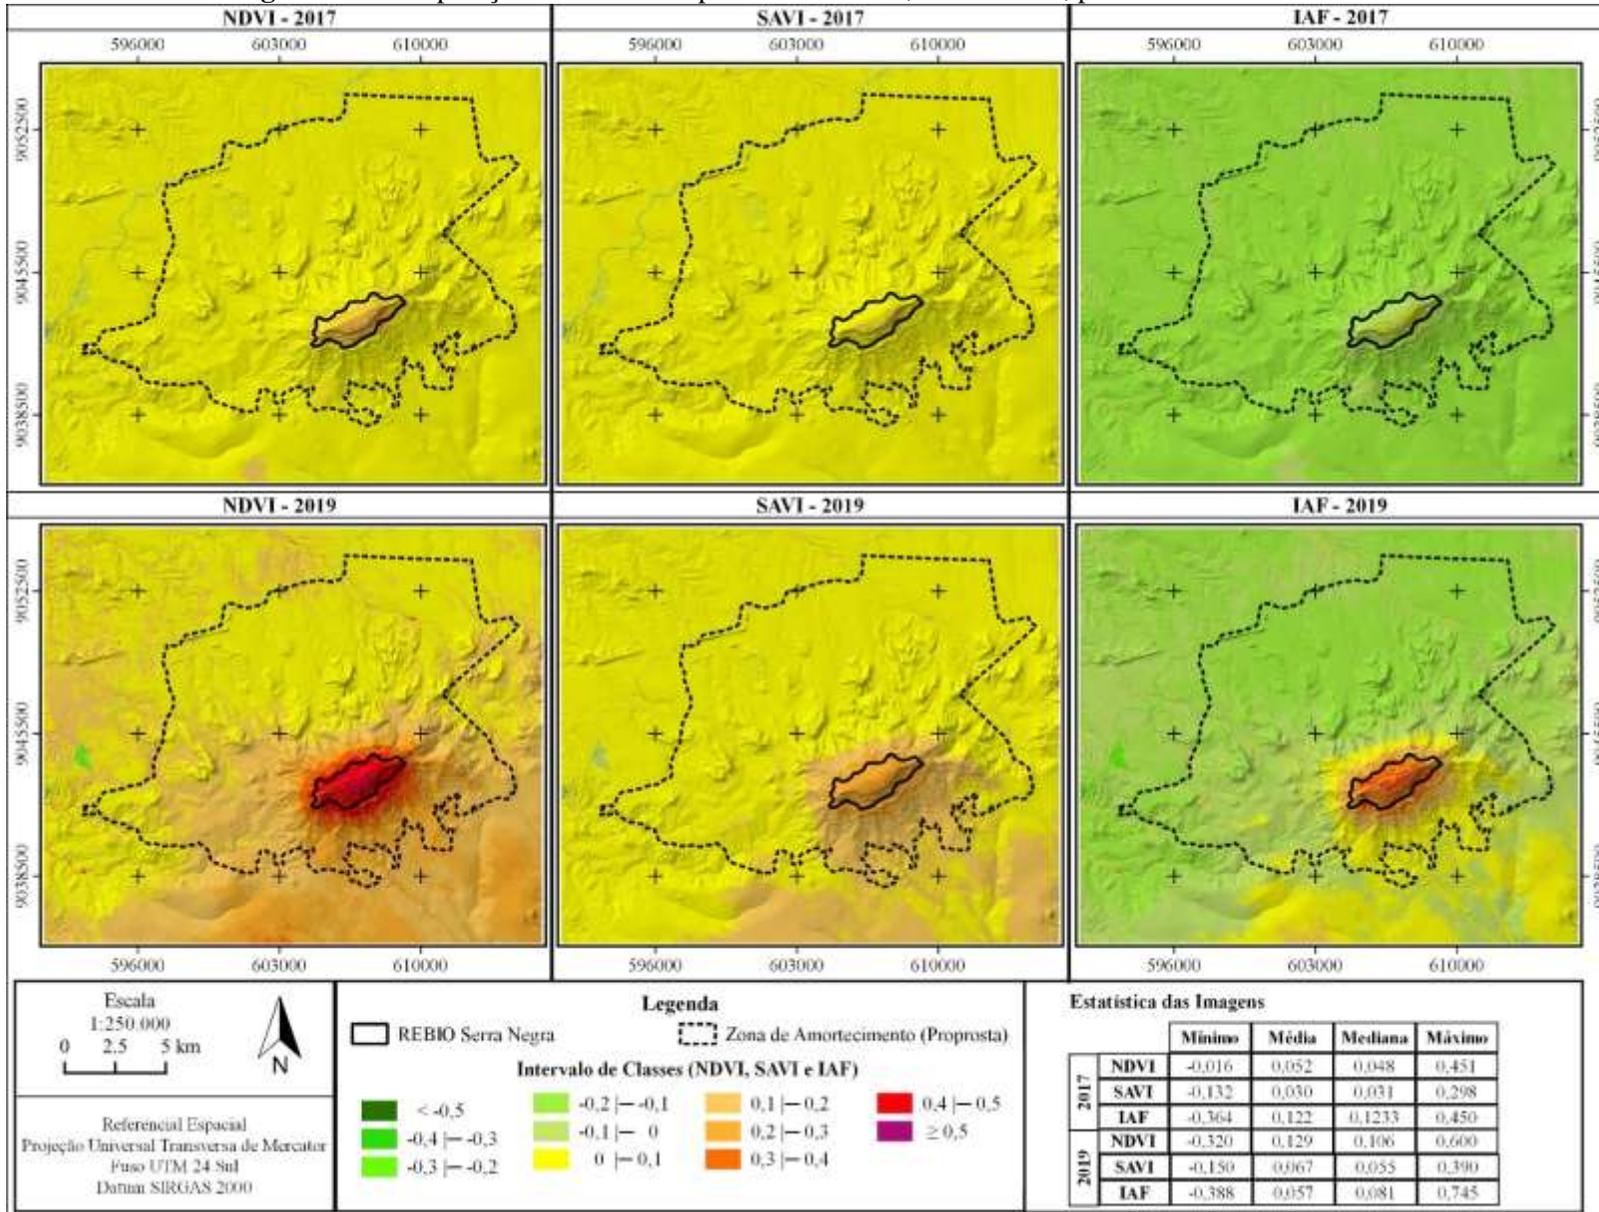
Fonte: Elaborado pelo autor (2021).

Nota-se que os valores de reflectância quando comparados entre os pares de classes, apresentaram diferenças significativa entre si. Em geral, as bandas do canal azul e verde apresentaram menores significância para separação da classe, enquanto que as bandas do canal vermelho (B7) e infravermelho-próximo (B8) apresentaram maiores diferenças significativas para discriminação das classes. Apesar da semelhança entres os intervalos de reflectância observados nos **Gráfico 5** a 7, estatisticamente esses valores são diferentes, portanto, pode-se afirmar que as imagens multiespectrais contribuíram para separação das classes com base na diferença da resposta espectral.

### 5.5.2 Índices espectrais

Os índices espectrais são resultado da razão entre a diferença da imagem de reflectância do infravermelho próximo (NIR) e do vermelho (Red) pela soma dessas mesmas bandas, para NDVI ao acréscimo do fator L para SAVI. Já o IAF é resultado da equação empírica (13), proposta por Allen; Tasumi; Trezza (2002), que tem como base a imagem do SAVI. Nas **Figura 26**, a seguir, comparou-se as imagens resultantes dos índices espectrais do NDVI, SAVI e IAF, para os anos bases de 2017 e 2019.

**Figura 26** - Comparação dos índices espectrais do NDVI, SAVI e IAF, para os anos 2017 e 2019.



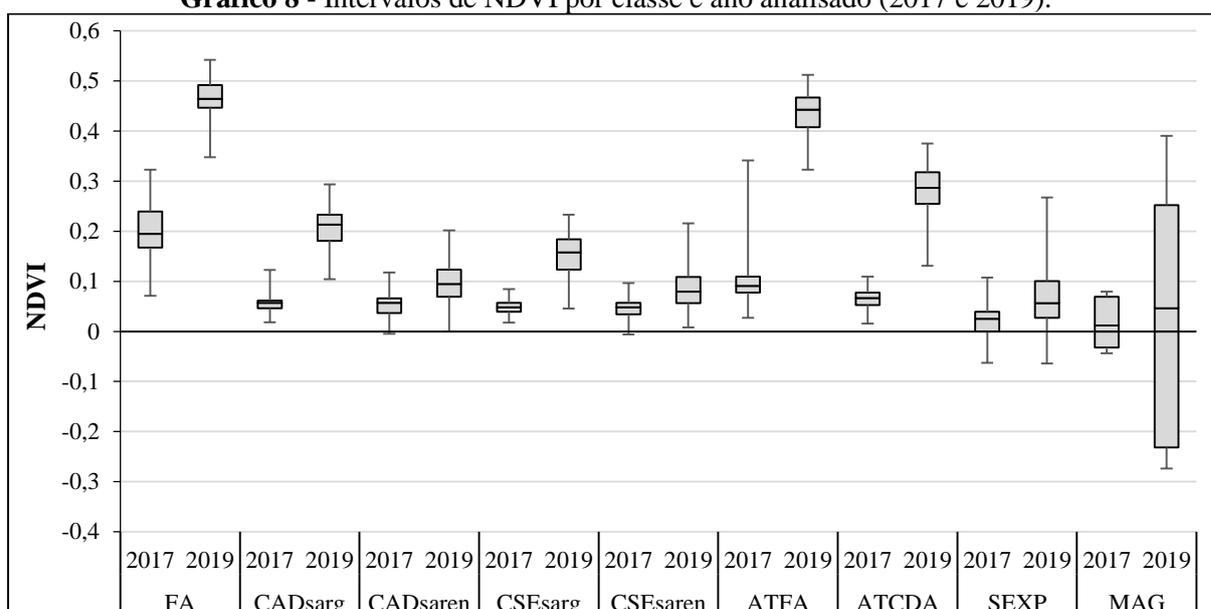
Fonte: Elaborado pelo autor (2021).

Analisando as imagens dos valores de NDVI (Figura 26), para o ano base de 2017, constatou que 96,60% dos valores encontra-se entre intervalo de 0 a 0,1 predominante para todas as classes, exceto para FA, que apresentou valores mais elevados; e já para o ano base 2019, 95,54% dos valores se encontram entre os intervalos de 0 a 0,3 predominando para as áreas de CAD e CSE; e 3,76% dos valores se encontra entre os intervalo de 0,3 a 0,6 predominando para as áreas de AT e FA. Sabe-se que os valores de NDVI variam entre -1 a +1, e quanto mais próximo de 1, maior é a densidade da cobertura vegetal, já os valores de NDVI  $< 0$  representa o valor aproximado para áreas com ausência de vegetação e corpos hídricos (POLONIO, 2015). Com a predominância de valores baixos de NDVI, indica que esse índice teve pouca influência para discriminação das classes.

Para o SAVI (Figura 26), o ano base de 2017, constatou que 98,45% dos valores encontra-se entre intervalo de 0 a 0,1, predominando para todas as classes; e para o ano base 2019, 97,21% dos valores se encontra entre os intervalo de 0 a 0,2, predominando para as áreas de SEXP, CAD e CSE; e 2,22% dos valores se encontra entre os intervalo de 0,2 a 0,4 predominando para as áreas de AT e FA. Sabe-se que os valores de SAVI também variam entre -1 para áreas com menor cobertura vegetal e +1 para áreas com cobertura vegetal mais densa, com a predominância de valores baixos de SAVI, indicando que esse índice também teve pouca influência para discriminação das classes de CAD, CSE e SEXP.

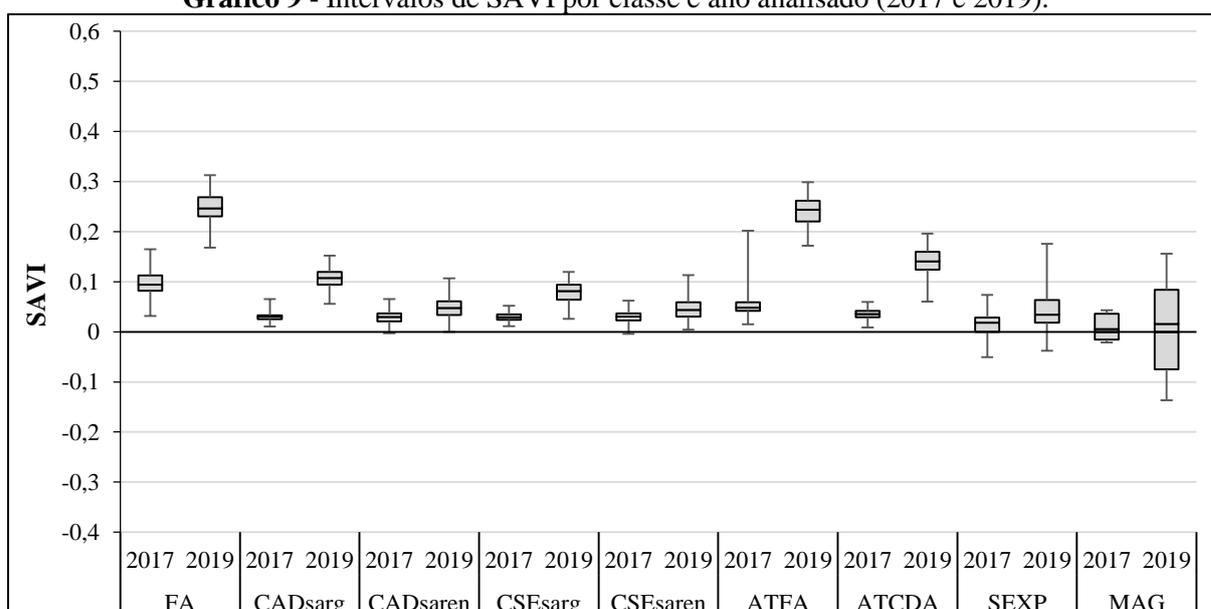
E para os valores de IAF (Figura 26), apresentaram uma variabilidade de -0,2 a 0,3, sendo que o intervalo entre 0,1 a 0,2 concentra 99,46% dos valores do índice para os anos bases de 2017. Já para o ano base 2019, o índice apresentou uma variabilidade de -0,4 a 0,8, sendo que o intervalo entre 0,1 a 0,2, concentra 95,55% dos valores. Para as áreas de AT e FA predominou os valores mais elevados de IAF, e os menores valores para áreas de SEXP e MAG. A concertação entre os intervalos 0,1 a 0,2 do IAF, também indicaram que esse índice obteve pouca influência para discriminação das classes de AT, CAD, CSE e SEXP.

Conforme pode ser observado na **Figura 26**, os índices espectrais apresentaram valores semelhantes entre as classes, indicando que a contribuição deles para as separações das classes foram baixas. Para melhorar o entendimento da contribuição dos índices espectrais para classificação foram elaborados gráficos (*Box Plot*) com base na amostragem de referência, a fim de avaliar a distribuição empírica das classes, entre os dois anos analisados. No **Gráfico 8**, a seguir, encontra-se os intervalos dos maiores e menores valores do NDVI encontrado por classes e a comparação entre os dois anos analisados (2017 e 2019).

**Gráfico 8** - Intervalos de NDVI por classe e ano analisado (2017 e 2019).

Fonte: Elaborado pelo autor (2021).

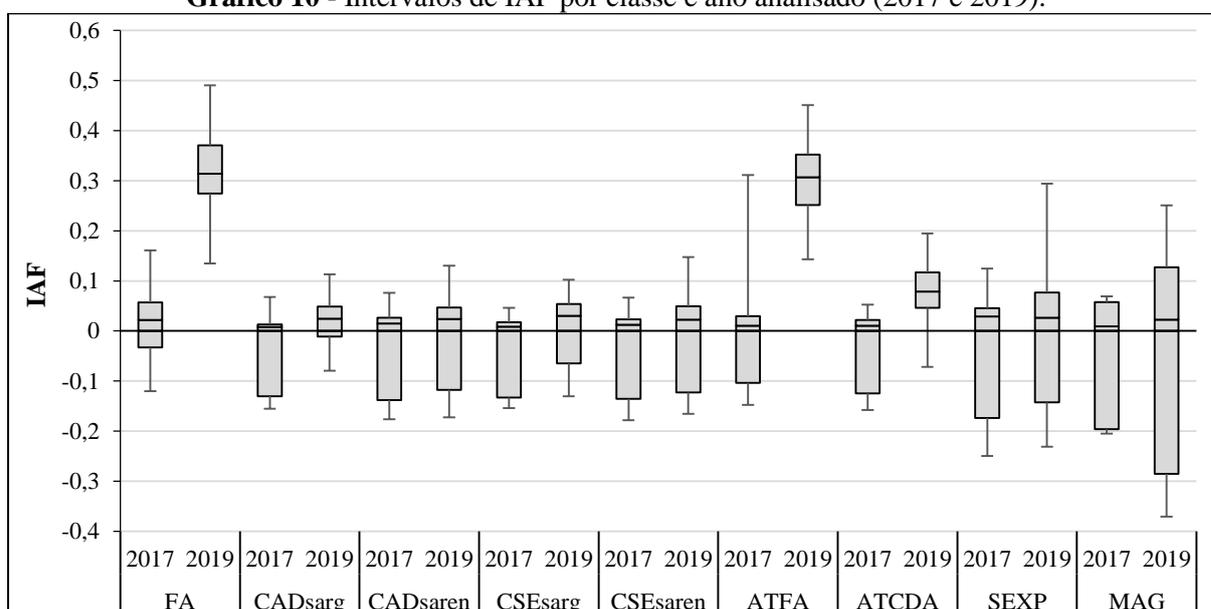
Pela análise do Gráfico 8, elaborado com base na amostragem de referência, pode-se observar que, os valores de NDVI para ano base 2019 são maiores, em comparação com ano base 2017, principalmente para áreas de maior cobertura vegetal. Em geral, a amostragem apresentou maior NDVI (0,341) para áreas AT<sub>FA</sub> e menor valor (-0,064) para área de SEXP, para amostragem do ano base 2017. Os maiores valores de NDVI (0,542) para área FA, e menor valor (-0,274) para área de MAG foram encontrados para amostragem do ano base 2019. No **Gráfico 9**, a seguir, estão os intervalos dos maiores e menores valores do SAVI, encontrado por classes e a comparação entre os dois anos analisados (2017 e 2019).

**Gráfico 9** - Intervalos de SAVI por classe e ano analisado (2017 e 2019).

Fonte: Elaborado pelo autor (2021).

Pela análise do **Gráfico 9**, elaborado com base na amostragem de referência, pode ser observado que os valores de SAVI para ano base 2019 são superiores aos do ano base 2017, exceto para áreas de MAG. Em geral, a amostragem apresentou maior valor de SAVI (0,202) para áreas AT<sub>FA</sub> e menor valor da área de SEXP (-0,050), para amostragem do ano base 2017; e os maiores valores de SAVI (0,312) para área FA, e menor valor (-0,136) para área de MAG, encontrados para amostragem do ano base 2019. No **Gráfico 10**, a seguir, estão os intervalos dos maiores e menores valores do IAF, encontrado por classes e a comparação entre os dois anos analisados (2017 e 2019).

**Gráfico 10** - Intervalos de IAF por classe e ano analisado (2017 e 2019).



Fonte: Elaborado pelo autor (2021).

Pela análise do **Gráfico 10**, elaborado com base na amostragem de referência, pode ser observado valores do IAF maiores para áreas de maior cobertura vegetal AT<sub>FA</sub> e FA. Pela amostragem do ano base 2017, observou-se que o maior valor de IAF (0,249) foi encontrado para as áreas AT<sub>FA</sub>, e o menor valor (-0,208) foi evidenciado para área de SEXP. Por outro lado, os maiores valores de IAF (0,374) para área FA, e menor valor (-0,300) para área de MAG, foram encontrados para amostragem do ano base 2019.

Pelas análises de significância do Teste de Soma de Postos de Wilcoxon (Mann-Whitney), para o ano base 2017 (Tabela 43), constatou que as áreas das classes de FA, AT e SEXP, no geral, apresentaram diferenças significativas entre os valores encontrados de NDVI, SAVI e IAF quando comparados com as demais classes. Já para a classe das áreas de CAD e CSE, quando comparados entre elas, não apresentaram diferenças significativas entre elas. Para

esse mesmo ano, as áreas de MAG também foi constatada diferenças significativas quando comparada com as áreas de FA, CAD, CSE e AT, exceto para áreas de SEXP.

**Tabela 43** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o NDVI do ano base 2017 (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,6080 <sup>ns</sup>	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,1300 <sup>ns</sup>	,4091 <sup>ns</sup>	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0085	,0648 <sup>ns</sup>	,6935 <sup>ns</sup>	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,00026	,0026	,0056	,0029	,0073	,00021	,0011	,3291 <sup>ns</sup>

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 44** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o SAVI e IAF do ano base 2017 (comparação entre classe).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,8861 <sup>ns</sup>	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,8622 <sup>ns</sup>	,7917 <sup>ns</sup>	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,7871 <sup>ns</sup>	,7681 <sup>ns</sup>	,7453 <sup>ns</sup>	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0003	,0000	,0001	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0003	,0029	,0058	,0028	,0042	,0002	,0011	,2728 <sup>ns</sup>

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

Já a análise de significância pelo Teste de Soma de Postos de Wilcoxon (Mann-Whitney), para o ano base 2019 (Tabela 45 e 46), observou-se que os valores de NDVI foram diferentes estatisticamente entre todas as classes. Já para os valores de SAVI e IAF não houve diferenças significativas apenas entre classes FA x AT<sub>FA</sub> e CSE<sub>saren</sub> x CAD<sub>saren</sub>.

**Tabela 45** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o NDVI do ano base 2019 (comparação entre classe).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0233	,0000	-	-	-	-
AT <sub>FA</sub>	,0001	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,0000	,0000	,0000	,0000	,0000	,0000	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

**Tabela 46** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para o SAVI e IAF do ano base 2019 (comparação entre classe).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0000	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,8500 <sup>ns</sup>	,0000	-	-	-	-
AT <sub>FA</sub>	,2100 <sup>ns</sup>	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0000	-	-
SEXP	,0000	,0000	,0110	,0000	,0130	,0000	,0000	-
MAG	,0000	,0000	,0000	,0000	,0000	,0000	,0000	,0000

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

Em geral, para os índices espectrais observou-se a análise de significância quando comparado aos pares das classes mapeadas, cujos valores de NDVI, SAVI e IAF apresentaram diferença significativa entre as classes, indicando que houve importância para a discriminação das mesmas. Ao longo de toda área de estudo, predominaram valores baixos de NDVI, SAVI e IAF, entre os intervalos de 0 a 0,2, para ambos os anos analisados (2017 e 2019). Esses baixos valores estão relacionados com a dinâmica das fitofisionomias da vegetação, que de acordo com o período do ano podem perder parte da folhagem resultando em menor cobertura vegetal. Os valores encontrados para o NDVI, SAVI e IAF para todos os períodos analisados foram inferiores aos encontrados por Oliveira (2013); Bezerra *et al.* (2014); Nascimento *et al.* (2014); Ribeiro (2016); Bilar *et al.* (2018); Figueirêdo *et al.* (2018), para regiões semiárida do Nordeste brasileiro.

Oliveira (2013), com objetivo principal de gerar subsídios para a gestão do uso e ocupação do solo na Zona de Amortecimento da Reserva Biológica Saltinho, situada no estado

de Pernambuco, utilizou índices espectrais do NDVI, SAV, IAF e NDWI, para diagnosticar o grau de preservação da UC. Ele utilizou imagens do satélite LANDSAT 5 TM, referentes as datas: 10/05/1996, 04/08/1998, 26/08/2006 e 06/09/2010 e encontrou valores superiores aos encontrados por essa pesquisa para os índices de NDVI, SAV, IAF. Em geral, nas áreas de vegetação mais densas predominaram os valores de NDVI entre o intervalo 0,51 a >0,71; e para o SAVI, os valores foram >0,60 em áreas de vegetação mais densa; e entre 0,5 a 0,3 para áreas de vegetação mais rala; >0,30 para áreas de pastagem, solo exposto, massa d'água e nuvens. Já para o IAF, predominou-se os valores superiores a 1,51 nas áreas de vegetação densa; e entre 0,81 a 1,5 para as áreas de vegetação de porte intermediário e de componentes arbóreas e arbustivos; e para as áreas de vegetação rasteira e plantações predominaram os valores entre 0,61 a 0,8. Esse autor relata que houve pequenas variações entre os valores dos índices entre uma classe de acordo com a época do ano analisado.

Bezerra *et al.* (2014), propôs avaliar a dinâmica espaço-temporal dos parâmetros biofísicos (albedo da superfície, NDVI e temperatura da superfície), na área de Caatinga do Parque Nacional da Fuma Feia, e suas adjacências em diferentes meses ao longo do período de 2007 e 2010, utilizando imagens do satélite LANDSAT - 5 TM. Observou-se que o autor supracitado obteve valores da ordem de 0,10 a 0,26 no período seco, que se concentraram em áreas de solo exposto e Caatinga mais aberta, mas para o período chuvoso os valores permaneceram entre 0,66 a 0,79, concentrando-se para áreas de vegetação mais densa. Esse mesmo autor afirma que seus resultados de NDVI foram superiores aos encontrados por Rodrigues *et al.* (2009), em estudo realizado para região semiárida do Ceará, na bacia hidrográfica do Rio Trussu, nos anos de 2000 e 2001, e os valores de NDVI foram da ordem de 0,003 a 0,20 para o período de estiagem; já no período de ocorrência de precipitações variou de 0,003 a 0,76, com predominância de valores na classe de 0,20 a 0,39.

Nascimento *et al.* (2014), com o objetivo de analisar a evolução temporal da cobertura vegetal na Sub-bacia do Alto Paraíba situada na microrregião do Cariri Paraibano, por meio do cálculo do NDVI, também obteve resultados superiores aos encontrados por essa pesquisa. Ele utilizou imagens do satélite LANDSAT - 5 TM, referentes aos anos de 1989 e 2004, para o cálculo do NDVI para área de Caatinga. Os resultados de NDVI para áreas de: Caatinga Arbustivo Aberta variou entre 0,2 a 0,4; Caatinga Semi-aberta entre 0,4 a 0,6 (predominantes em 47% da área); Caatinga Arbustivo-arbórea entre 0,6 a 0,8 (predominantes em 23% da área); e para áreas Caatinga Arbórea-arbustiva entre 0,8 a 1, entre dois períodos avaliados.

Bilar *et al.* (2018), identificou a condição da cobertura vegetal para o Parque Estadual Mata da Pimenteira (PEMP) no município de Serra Talhada/PE, através da aplicação de índices biofísicos: NDVI, IAF, SAVI, EVI e NDWI, gerados a partir da análise de imagens orbitais do satélite LANDSAT - 5 TM e 8 OLI referentes aos anos de 2007, 2013 e 2016. Dos resultados obtidos para a imagem do dia base 26/07/2007, predominaram os valores de NDVI > 0,40; SAVI > 0,30; e IAF < 0,20; já para a imagem do dia base 28/09/2007, destacaram-se os valores predominantes do NDVI < 0,30; SAVI < 0,20; e IAF < 0,25; e para a imagem do dia base 24/06/2013, predominaram os valores NDVI > 0,50; SAVI > 0,30; e IAF entre 0,60 e 0,80; e para a imagem do dia base 03/08/2016, predominaram os valores de NDVI < 0,40; SAVI < 0,30; e para o IAF entre o intervalo de 0,25 a 0,49.

Figueirêdo *et al.* (2018), utilizando imagens do LANDSAT - 5 TM, para área da bacia do Alto Ipanema, situada no Agreste Pernambucano e próximo a área de estudo, para o período correspondente ao mês de setembro período seco na região de estudo, para os dias 23/09/2008 e 29/09/2010, obteve valores médios de NDVI de 0,401 (2008) e 0,402 (2010), e valores médios do SAVI 0,273 para os dois períodos avaliados. De acordo com esse autor, para as áreas de vegetação intermediária obteve-se NDVI entre 0,5 - 0,6 e superiores a 0,6 para áreas de vegetação mais densa. Para o SAVI foi obtido valores entre 0,3 a 0,5 para áreas de vegetação intermediária, ao passo que os valores superiores a 0,5 foram encontrados nas áreas de vegetação mais densa. Os baixos valores dos índices espectrais de vegetação encontrados podem estar relacionados à época do ano do imageamento das imagens, realizado em período seco, refletindo menor densidade de cobertura vegetal para área de estudo (FIGUEIRÊDO *et al.*, 2018). Oliveira e Galvêncio (2008), verificaram condições similares de baixo índice de vegetação na bacia do rio Moxotó, também próximo a REBIO de Serra Negra, na região semiárida de Pernambuco, com imagens imageadas nos meses de setembro e outubro.

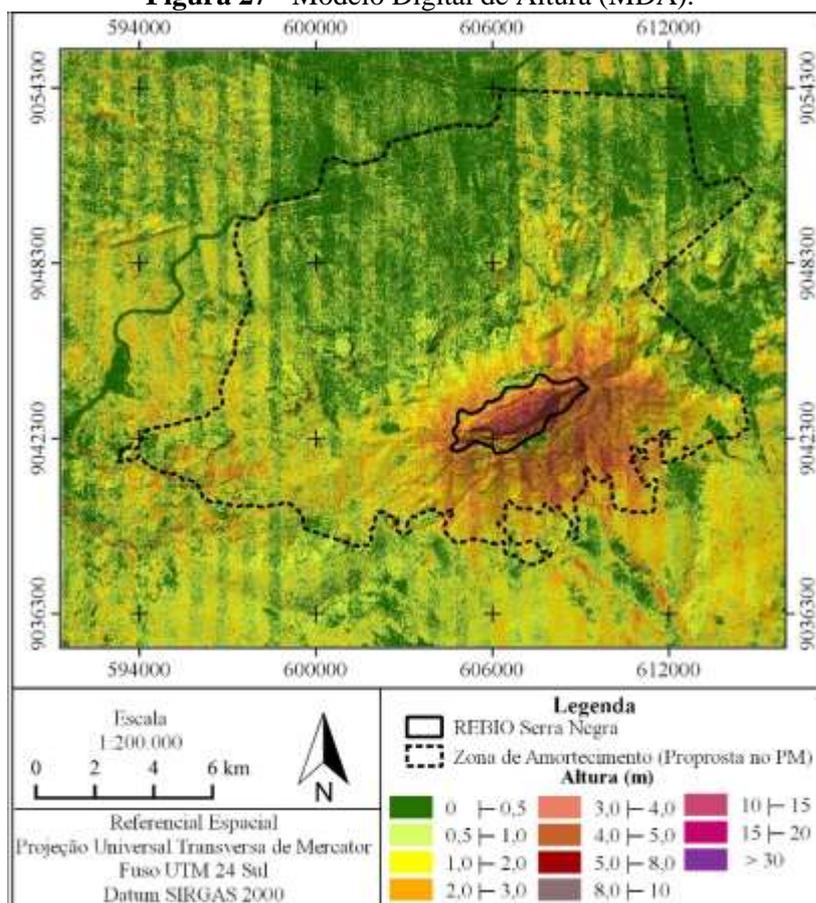
Para o bioma da Caatinga, não foram encontradas na literatura, a utilização de imagens do satélite CBERS - 4, para geração dos NDVI, SAVI e IAF. Neves e Mucida (2020), fez comparações de índices de vegetação (NDVI e SAVI) entre imagens do satélite CBERS - 4, LANDSAT - 8 (OLI) e Rapideye para área do Cerrado, entre os municípios de Gouveia e Datas, no estado de Minas Gerais. Porém, não conseguiram gerar as imagens do SAVI para as imagens do satélite CBERS - 4, no entanto, o NDVI obtido se mostrou mais eficiente na diferenciação das classes amostradas, em comparação com LANDSAT - 8, fato também destacado por Martins *et al.* (2018). Quanto em termos comparativos, o CBERS-4 apresentou valores mais próximos ao satélite Rapideye. A pouca variação encontrada entre os valores de NDVI entre as

imagens CBERS-4 e Rapideye caracteriza a neutralidade ou similaridade entre as imagens (MARTINS *et al.*, 2018).

### 5.5.3 MDA

O MDA é o resultado da subtração algébrica entre o MDE – MDT, e representa apenas a altura dos objetos acima do terreno (**Figura 27**), que de acordo com Pereira e Centeno (2017), simplificaria a análise. Os dados do MDA foram integrados no processo de segmentação multirresolução com intuito de acrescentar o atributo da altura dos objetos no processo de segmentação e mineração de dados para diferenciação das classes mapeadas. Com o mesmo objetivo do MDA, os índices espectrais (NDVI, SAVI e IAF) foram integrados ao processo segmentação multirresolução e mineração de dados.

**Figura 27 - Modelo Digital de Altura (MDA).**



Fonte: Elaborado pelo autor (2021).

Com base na **Figura 27**, e na **Tabela 47** - Resumo estatístico da altura do objetos por classe.a seguir, notou-se que as maiores alturas são para áreas de FA e AT, onde se encontra maior representatividade de espécies de maior porte arbóreo. Há uma inconsistência no MDA

em relação a áreas de MAG e SEXP, já que foram encontradas valores de altura superior a 1m. Já nas áreas de CAD e CSE os valores de altura estão dentro do estratos de ocorrência de espécies com porte arbóreo (8 a 12m), arbustivo (2 a 5m) e herbáceo (abaixo de 2m).

**Tabela 47** - Resumo estatístico da altura do objetos por classe.

Classe	Mínimo (m)	Média (m)	Mediana	Máxima (m)	Desvio Padrão
FA	0,784	8,891	8,194	24,892	5,735
CAD <sub>sarg</sub>	0,093	1,638	1,612	3,459	0,715
CAD <sub>saren</sub>	0,023	1,237	1,052	4,491	0,842
CSE <sub>sarg</sub>	0,047	0,952	0,901	3,678	0,652
CSE <sub>saren</sub>	0,024	0,903	0,629	4,421	0,897
AT <sub>FA</sub>	0,216	4,056	3,937	9,324	1,818
AT <sub>CDA</sub>	1,198	3,533	3,323	7,683	1,187
SEXP	0,010	0,281	0,081	8,551	0,776
MAG	0,001	0,564	0,150	3,241	0,914
**MDA	0,000	1,427	1,136	37,714	1,307

\*\*MDA = Média geral do Modelo Digital de Altura.

Fonte: Elaborado pelo autor (2021).

Pela **Tabela 47**, os valores da média e mediana para áreas de SEXP e MAG apontaram uma tendência de baixas altitudes, como esperado para essas áreas. As médias e medianas apontaram também para áreas de CSE, e predominaram as alturas dos estratos dos componentes herbáceos, mas é importante destacar que para essa classe, foram incluídas as áreas anteriormente antropizadas e o estágio de recuperação.

Pelo Teste de Soma de Postos de Wilcoxon (Mann-Whitney) e com base nas amostras de referência do MDA, constatou-se que houve diferença significativa entre altura da vegetação quando comparados entre quase todas as classes, exceto para áreas de CSE<sub>sarg</sub> x CAD<sub>saren</sub>, CSE<sub>sarg</sub> x CSE<sub>saren</sub> e MAG x SEXP (Tabela 48).

**Tabela 48** - Teste de Soma de Postos de Wilcoxon (Mann-Whitney) com correção de continuidade para MDA (comparação entre classes).

Classes	FA	CAD <sub>sarg</sub>	CAD <sub>saren</sub>	CSE <sub>sarg</sub>	CSE <sub>saren</sub>	AT <sub>FA</sub>	AT <sub>CDA</sub>	SEXP
CAD <sub>sarg</sub>	,0000	-	-	-	-	-	-	-
CAD <sub>saren</sub>	,0000	,0000	-	-	-	-	-	-
CSE <sub>sarg</sub>	,0000	,0000	,0149 <sup>ns</sup>	-	-	-	-	-
CSE <sub>saren</sub>	,0000	,0000	,0000	,0504 <sup>ns</sup>	-	-	-	-
AT <sub>FA</sub>	,0000	,0000	,0000	,0000	,0000	-	-	-
AT <sub>CDA</sub>	,0000	,0000	,0000	,0000	,0000	,0123	-	-
SEXP	,0000	,0000	,0000	,0000	,0000	,0000	,0000	-
MAG	,0000	,0000	,00017	,0017	,0101	,0000	,0000	,2974 <sup>ns</sup>

\*Para o Teste de Soma de Postos de Wilcoxon (Mann-Whitney), a diferença entre as medianas são estatisticamente significativa quando  $P\text{-valor} \leq 0,05$  ( $\alpha$ ), (rejeito:  $H_0$ ).

<sup>ns</sup> = não significante.

Fonte: Elaborado pelo autor (2021).

Pela análise de significância (Tabela 48) do MDA, a altura dos objetos agregaram informações importantes a serem utilizadas na classificação das fitofisionomias vegetação,

como também já observados por outros autores como Mendes e Dal Poz (2011), Francisco e Almeida (2013); Tedesco *et al.* (2014); Sothe (2015).

Mendes e Dal Poz (2011), utilizaram dados altimétricos de varredura a laser e imagem aérea multiespectrais (RGB) alta-resolução, com objetivo isolar vias em ambientes urbanos na cidade de Curitiba-PR, por meio de técnicas classificação por Redes Neurais Artificiais implantada no *software* IDRISI. Para os resultados da classificação, que inclui os dados de entrada, a imagem de altura obteve resultado superior aos encontrados para classificação que utilizou puramente dados espectrais. E segundo esses mesmos autores ao analisar as matrizes de erro geradas, observou-se que a imagem de altura ajudou a diminuir a confusão existente entre as classes que representam objetos que possuem comportamento espectral semelhantes. Já Tedesco *et al.* (2014) utilizaram um MDA para a discriminação entre vegetação arbórea e rasteira, e obteve acurácia de 100% na discriminação destas duas classes. Francisco e Almeida (2013) demonstraram a importância da inclusão de outras informações, não somente espectrais para a discriminação das classes de cobertura da terra, sendo que o atributo declividade foi capaz de discriminar duas classes (afloramento rochoso e vegetação herbácea rala) que apresentavam respostas espectrais e texturais semelhantes na árvore de decisão.

#### **5.5.4 Atributos texturais**

Para o processo de classificação também foram utilizados os atributos texturais de entropia (GLCM) e homogeneidade (GLCM), proposto por Haralick *et al.* (1973). De acordo com Francisco e Almeida (2012), as medidas de entropia medem a desordem da imagem, enquanto a homogeneidade mede a homogeneidade da mesma, sendo considerados por Baraldi e Parmiggiani (1995); e Ito *et al.* (2011), como os atributos texturais de maior relevância. Para todos os planos de informação pelo teste de raqueamento do WEKA, o atributo de textural de homogeneidade para as bandas do vermelho e infravermelho-próximo foram de maior peso para separação das classes, enquanto a entropia apresentou maior peso para bandas do verde e azul. No geral, os atributos texturais foram importantes para a discriminação das classes. Segundo Furtado (2013), a utilização de informação textural é apontada em vários estudos para melhor discriminação de classes de vegetação (YU *et al.*, 2006), bem como de classes antrópicas (DEKKER, 2003; DELL'ACQUA; GAMBA, 2003; FRANCISCO; ALMEIDA, 2012; BRANCO *et al.*, 2018).

## 6 CONCLUSÕES E RECOMENDAÇÕES

Todos os resultados encontrados foram satisfatórios e atenderam aos objetivos propostos. Dos resultados obtidos tanto visualmente (Figura 21 a 22), quanto às análises estatísticas (**Gráfico 3 a 10** e as **Tabela 16 a 48**), apresentaram semelhanças significativas, sendo possível observar algumas diferenças pontuais, mas não determinaram qual dos planos de informação (I ao VIII) obteve um desempenho superior. Em geral, os índices de exatidões globais foram superiores a 80%, e os indicadores de concordância Kappa variaram entre 0,81 a 0,86, e os testes de significância z, indicaram que quase não houve diferença significativa entres os Kappas considerando os diferentes planos de informação e épocas analisadas (2017 e 2019). O plano de informação IV além do resultado satisfatório, apresentou uma relação melhor entre o tempo de processamento e o número de atributos agregados para classificação.

Como observado nas classificações geradas, a diferença entre as imagens de origem ao final do período seco (2017) e chuvoso (2019), contribuíram para identificação de áreas de CAD, anteriormente classificadas como áreas CSE. As áreas de CAD, CSE e SEXP foram bem identificadas em ambos os anos analisados, já as áreas de FA foram melhor identificadas para os planos de informação com base no ano de 2017. Em contrapartida, as áreas transição  $AT_{FA}$  e  $AT_{CDA}$  foram melhores delimitadas para os planos de informação do ano base 2019. Fatores como a sazonalidade e dinâmica da composição da vegetação da região e similaridade entre às áreas de AT, CAD e CSE colaboraram para as variações dessas classes entre um ano e outro. As regiões de MAG não foram bem delimitadas devido à ausência de áreas amostrais, e para as imagens do ano base 2019, foram identificadas várias áreas como MAG em meio a áreas de CAD e CSE.

Os diferentes planos de informação organizados utilizando as imagens multiespectrais, índices espectrais e MDA, contribuiu para a discriminação das diferentes fitofisionomias presentes na REBIO Serra Negra. Pelos testes de Soma de Postos de Wilcoxon (Mann-Whitney), confirmou-se as diferenças significativas entres os atributos, quando comparados entres os pares das classes. Tanto visualmente quanto nas análises estatísticas não ocorreram diferença significativa entre os resultados com uso de imagens fusionadas ou não fusionadas. A melhoria da resolução espacial das imagens pela técnicas de fusão Pansharpening RCS (Substituição de Componente de Proporção), melhoram a discriminação de alguns objetos (clareiras), devido à melhor identificação dos objetos no solo.

O método de segmentação multirresolução orientada ao objeto, permitiu alcançar um bom nível de detalhamento no mapeamento, bem como boas classificações. Ele também apresentou vantagem na integração de dados de múltiplos sensores e diferentes resoluções espaciais, além da utilização de atributos texturais (homogeneidade e entropia) e estatísticos. A técnica de mineração de dados utilizando o método de classificação baseado em Rede Neural Artificial se mostrou eficiente na integração de múltiplos sensores e na classificação final dos resultados. E a utilização das imagens de média resolução espacial do satélite CBERS - 4 integradas aos produtos do programa PE3d, se mostraram eficientes na delimitação dos diferentes contornos das fitofisionomias da vegetação e áreas antrópicas presentes na Zona de Amortecimento da REBIO de Serra Negra. Os métodos adotados para classificação e os resultados satisfatórios obtidos por esta pesquisa, poderão servir de base para novos estudos visando o monitoramento contínuo dessas áreas protegidas para conservação da mesma.

E por fim, pode-se concluir que no interior da Zona de Amortecimento da REBIO Serra Negra, ao longo dos períodos analisados (2017 - 2019), não foram constatadas grandes alterações de uso e ocupação da Terra. Em áreas identificadas anteriormente como regiões antrópicas (2017), posteriormente (2019) observou-se a recuperação da cobertura vegetal perdida. Esses resultados mostraram que a UC encontra-se em boas condições de preservação ambiental, diferentes das áreas ao entorno, onde foram identificadas a construção de um barramento d'água e limpeza de terrenos para agricultura.

## 6.1 RECOMENDAÇÕES E SUGESTÕES

Para os trabalhos subsequentes propõe-se um raqueamento dos atributos mais importantes para discriminação das classes e normalização dos dados, a fim de melhorar o desempenho e tempo de processamento da RNA. Recomenda-se também testar outros algoritmos de mineração de dados, como os baseados em árvore de decisão (C4.5, Random Florest), para classificação de dados multitemporais e de multifontes. Para os trabalhos futuros em que desejam utilizar o MDA resultante dos produtos do PE3d, como atributo para auxiliar no processo de classificação, recomenda-se o uso nas áreas naturais onde não ocorreram mudanças abruptas na superfície da região estudada.

## REFERÊNCIAS

- ABDIKAN, S.; SANLI, F. B. Comparison of different fusion algorithms in urban and agricultural areas using sar (palsar and radarsat) and optical (spot) images. **Boletim de Ciências Geodésicas**, Curitiba, v. 18, n. 4, p. 509-531, 2012.
- ACHANCCARAY DIAZ, P. M. A **Comparasion of Segmentation Algorithms for Remote Sensing**. 84 f. 2014. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2014.
- ADAMI, M. Fusão de imagens por IHS para melhorar a identificação de uso do solo em elementos amostrais. **Engenharia Agrícola**, Jaboticabal, v. 27, n. 2, May/Aug., 2007.
- AGOSTINI, M. Estudo **Comparativo Entre as Ferramentas WEKA e SAS no processo de descoberta de informações**. 2017. 55 f. Monografia (Especialização em Banco de Dados) - Instituto de Computação da Universidade Federal de Mato Grosso, Cuiabá, 2017.
- ALBA, E.; PEREIRA, R. S. DIEL, G. F.; MELLO, E. P.; SILVA, E. A.; TRAMONTINA, J. Uso da resposta espectral na identificação e monitoramento de espécies florestais a partir de imagens de média resolução espacial. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** João Pessoa: INPE, 2015.
- ALLEN, R. G.; TASUMI, M.; MORSE, A.; TREZZA, R. A LANDSAT-based energy balance and evapotranspiration model in Western US water rights regulation and planning. **Irrigation and Drainage Systems**, Brussels, Belgium, v. 19, p. 251-268, 2005.
- ALLEN, R.; TASUMI, M.; TREZZA, R. **SEBAL (Surface Energy Balance Algorithms for Land): advanced training and user's manual - Idaho implementation**. [S.n.: S.I], 2002. 98 p. (Version 1.0)
- ALMEIDA FILHO, R.; NASCIMENTO, P. S. R.; BATISTA, G. T. Avaliação de técnicas de segmentação e classificação automática de imagens LANDSAT-TM no mapeamento do uso do solo na Amazônia. **Acta Amazonica**, Manaus, v. 28, n. 1, p. 41-54, 1998.
- ALMEIDA, A. Q. de; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. de; LEITE, F. P. Índice de Área Foliar de *Eucalyptus* Estimado por Índices de Vegetação Utilizando Imagens TM - LANDSAT 5. **Floresta e Ambiente**, Seropédica, v. 22 n. 3, p. 368-376, 2015. <http://dx.doi.org/10.1590/2179-8087.103414>.
- ALMEIDA, A. S. de; WERNECK, G. L.; RESENDES, A. P. da C. Classificação orientada a objeto de imagens de sensoriamento remoto em estudos epidemiológicos sobre leishmaniose visceral em área urbana. **Cadernos de Saúde Pública**, Rio de Janeiro, v. 30, n. 8, Aug. 2014.
- AMARAL, F. **Aprenda mineração de dados: teoria e prática**. Rio de Janeiro: Alta Books Editora, 2016, 220 p.
- AMARAL, M. V. F.; SOUZA, A. L. de; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. G.; MARTINS, S. V.; FERNANDES FILHO, E. I.; LANA, J. M. de. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, Viçosa, v. 33, n. 3, p. 575-582, May/June, 2009. Disponível em: <<http://dx.doi.org/10.1590/S0100-67622009000300019>>. Acesso em 08 nov. 2019.

AMRO, I.; MATEOS, J.; VEGA, M.; MOLINA, R.; KATSAGGELOS, A. K. A survey of classical methods and new trends in pansharpening of multispectral images. **EURASIP Journal on Advances in Signal Processing**, [S.l.], v. 2011, n. 79, p. 1–22. Set., 2011. Disponível em: <<http://asp.eurasipjournals.com/content/2011/1/79>>. Acesso em 01 jun. 2020.

ANA - Agência Nacional de Águas (2020). **Massas d'água**. Brasília. Disponível em: <<https://metadados.ana.gov.br/geonetwork>>. Acesso em 10 jan. 2020.

ANA - Agência Nacional de Águas. **Base Hidrográfica Ottocodificada Multiescalas 2013**. Brasília: ANA, 2013. 1 Mapa digital. Escala 1:1.000.000. Disponível em: <<http://metadados.ana.gov.br/geonetwork/srv/pt/main.home?uuiid=7bb15389-1016-4d5b-9480-5f1acdadd0f5>>. Acesso em 01 mar. 2020.

ANDRADE, A. F. Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais. **Bol. Ciênc. Geod.**, Curitiba, v. 9, n. 1, p. 152-153, 2003.

ANDRADE, A. F.; BOTELHO, M. F.; CENTENO, J. A. S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 11., 2003, Belo Horizonte. **Anais...** Belo Horizonte: INPE, 2003. p. 265-272.

ANTUNES, A. F. B. Object oriented analysis and semantic network for high resolution image classification. **Boletim de Ciências Geodésicas**, Curitiba, v. 9, n. 2, 2003.

ARTERO, A. O. **Técnicas para a extração automática de feições retas em imagens digitais**. 1999. 117 f. Dissertação (Mestre em Ciências) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, Programa de Pós-Graduação em Ciências Cartográficas, Presidente Prudente, 1999.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: STROBL, J. BLASCHKE, T.; GRIESEBNER, G. (Eds.). **ANGEWANDTE GEOGRAPHISCHE INFORMATIONEN VERARBEITUNG 12., BEITRÄGE ZUM AGITSYMPIOSIUM SALZBURG, 12.**, 2000, Wichmann Verlag, Karlsruhe, Germany. **Proceedings...** Karlsruhe: Herbert Wichmann, 2000. p. 12 – 23.

BAEZA, S.; PARUELO, J. M. Land Use/Land Cover Change (2000–2014) in the Rio de la Plata Grasslands: An Analysis Based on MODIS NDVI Time Series. **Remote Sensing**, [S.l.], v. 12, n. 3, p. 381, 2020.

BARALDI, A.; PARMIGGIANI, F. An Investigation of the Textural Characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 33, n. 2, p. 293-304, 1995.

BARBOSA, D. C. C. **Mineração de dados usando o software Wizrule em base de dados de compras de itens de TI**. 2007. 80 f. Dissertação (Mestrado Profissionalizante em Administração) - Faculdade de Economia de Finanças IBMEC, Rio de Janeiro, 2007.

BARCA, M. C. S.; SILVEIRA, T. R. d. S.; MAGINI, M. Treinamento de redes neurais artificiais: o algoritmo backpropagation. In: ENCONTRO LATINO AMERICANO DE INICIAÇÃO CIENTÍFICA, 9.; ENCONTRO LATINO AMERICANO DE PÓS-

GRADUAÇÃO – UNIVERSIDADE DO VALE DO PARAÍBA, 5., 2005, Jacareí. **Anais...** Jacareí: Univap, 2005, p. 46-49.

BARCELOS, A. F.; TOSHIMITSU, H. S. Modelo matemático neural artificial para cálculo de rendimento metálico teórico de um laminador de tiras a frio. In: SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA (SEGET), 15., 2018, Resende, RJ. **Anais...** Niterói: UFF, 2018.

BARROS, A. C. de; SILVA, T. J. da; COSTA, D. de M. Sensoriamento remoto na análise ambiental da microbacia do Córrego da Água Amarela, Itaberá/SP. **Holos Environment**, Rio Claro, SP, v. 16, n. 1, p. 27-35, 2016. ISSN 1519-8634 (On-line).

BENTO, B. M. P. Avaliação de classificadores por árvore de decisão e árvore de regressão em cenas urbanas do sensor Worldview-2. 2017. 140 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v. 58, n. 3-4, p. 239–258, jan., 2004. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271603000601>>. Acesso em 10 jan. 2021.

BERGER, R.; SILVA, J. A. A.; FERREIRA, R. L. C.; CANDEIAS, A. L. B.; RUBILAR, R. Índices de vegetação para a estimativa do índice de área foliar em plantios clonais de *Eucalyptus saligna* Smith. **Ci. Fl.**, Santa Maria, v. 29, n. 2, p. 885-899, abr./jun. 2019.

BEZERRA, J. M.; MOURA, G. B. A.; SILVA, G. B.; LOPES, P. M. O.; SILVA, E. F. F. Parâmetros biofísicos obtidos por sensoriamento remoto em região semiárida do estado do Rio Grande do Norte, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 18, n. 1, p. 73-84, 2014.

BHASKARRAJAN, N. J. Satellite Image Fusion using IHS and PCA Method. **International Journal of Innovative Science**, [S.l.], v. 1, n. 7, p. 152-156, 2014.

BIGOLIN, N. M.; BOGORNY, V.; ALVARES, L. O. Uma Linguagem de Consulta para Mineração de Dados em Banco de Dados Geográficos Orientado a Objetos. In: CONFERENCIA LATINOAMERICANA DE INFORMATICA, 29., 2003, La Paz. **Anais...** La Paz: CLEI, 2003. p. 23-35.

BILAR, A. B. C.; PIMENTEL, R. M. M.; CERQUEIRA, M. A. Monitoramento da cobertura vegetal através de índices biofísicos e gestão de áreas protegidas. **Revista Geosul**, Florianópolis, v. 33, n. 68, p.236-259, set./dez. 2018.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford: Clarendon Press, 1995.

BORATTO, I. M. P.; GOMIDE, R. L. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO. (SBSR), 16., Foz do Iguaçu-PR. **Anais...** São José dos Campos: INPE. p. 7345-7352, 2013.

BOTELHO, M. F.; CENTENO, J. A. S. Uso integrado de imagem de alta resolução espacial e altura derivada do laser scanner na escolha do classificador orientado a região. **Boletim de Ciências Geodésicas, Sec. Artigos**, Curitiba, v. 11, n. 1, p. 71-87, jan./jun. 2005.

BRAGA, A. P.; LUDENIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: teorias e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2007.

BRAGA, B. C.; FREITAS, C. da C.; SANT'ANNA, S. J. S. Classificação multifontes de imagens de sensoriamento remoto baseada em mapas de incertezas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 4474- 4481.

BRANCO, T. L.; FIDALGO, E. C. C.; FRANCISCO, C. N.; DART, R. de O.; PRADO, R. B. Análise orientada a objetos para a classificação do uso e cobertura da Terra do assentamento São José da Boa Morte, RJ. Rio de Janeiro, RJ: Embrapa Solos, 2018. 36 p. (Boletim de Pesquisa e Desenvolvimento (265). Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/>>. Acesso em 25 ago. 2020.

BRASIL. Decreto nº 87.591, de 20 de setembro de 1982. Cria, no Estado de Pernambuco, a Reserva Biológica de Serra Negra. **Diário Oficial [da] República Federativa do Brasil**, Poder Executivo, Brasília, DF, 21 set. 1982. Seção 1, p. 17699.

\_\_\_\_\_. Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio); Ministério do Meio Ambiente (MMA): **Plano de Manejo: Reserva Biológica da Serra Negra**. Brasília: ICMBio; MMA, 2011a. v. 1, 317 p.

\_\_\_\_\_. Ministério do Meio Ambiente (MMA). Sistema Nacional de Unidades de Conservação da Natureza (SNUC): **Lei nº 9.985, de 18 de julho de 2000; Decreto nº 4.340, de 22 de agosto de 2002**. Brasília: MMA, 2011b. 76 p.

BRYN, L. M. **Página dinâmica para aprendizado do sensoriamento remoto**. 2008. 172 f. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Porto Alegre, 2008. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/13788>>. Acesso em 07 nov. 2019.

CAMARA, G, SOUZA R. C. M, FREITAS, U. M, GARRIDO, J. SPRING: **Integrating remote sensing and GIS by object-oriented data modelling**. Computers e Graphics, São José dos Campos, v. 20, n. 3, p. 395- 403, May/Jun. 1996. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/index.html>>. Acesso em 25 out. 2019.

CAMPBELL, J. B.; WYNNE, R. H. *Introduction to Remote Sensing*. 4.ed. 2011.

CANAVESI, V. *et al.* Estimativa de volume de madeira em plantios de *Eucalyptus spp.* utilizando dados hiperespectrais e dados topográficos. **Revista Árvore**, Viçosa, v. 34, p. 539-549, 2010.

CARLEER, A. P.; DEBEIR, O.; WOLFF, E. Assesment of very high spatial resolution satellite image segmentations. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v. 71, n. 11, p. 1285–1294, 2005.

CARVALHO, M. V. A. **Classificação da cobertura e uso do solo com imagens Worldview-2 utilizando mineração de dados e análise baseada em objetos**. 2011. 201 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.

CARVALHO, M. V. A.; SILVA, G. F.; CRUZ, C. B. M.; ALMEIDA P. M. M. Avaliação do mapeamento de manguezais na Região Metropolitana do Rio de Janeiro através da integração entre GEOBIA e Mineração de Dados. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** João Pessoa: INPE, p. 3580 – 3587, 2015.

CARVALHO, T. R. A. de. **Índice de área foliar em Caatinga preservada: avaliação *in-situ* e através da resposta espectral da vegetação**. 2016. 79 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal do Ceará, Centro de Ciências Agrárias, Departamento de Engenharia Agrícola, Programa de Pós -Graduação em Engenharia Agrícola, Fortaleza, 2016.

CASTANHEIRA, L. G. **Aplicação de Técnica de Mineração de Dados em Problemas de Classificação de Padrões**. 2008. 94 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

CASTRO, L. F.; FIDALGO, E. C. C.; PRADO, R. B. Análise orientada a objetos aplicada a imagem de alta resolução para identificação de solo exposto em ambiente montanhoso de Mata Atlântica. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos, SP. **Anais...** São José dos Campos: INPE, 2017. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3PS4GRG>>. Acesso em 30 de jul. de 2020.

CHAGAS, C. S.; VIEIRA, C. A. O.; FERNANDES FILHO, E. I.; C. JÚNIOR, W. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 3, p. 319–327, 2009.

CHAPLIN, C. **Vida e Pensamentos**. [S.l.]: Editora Martin Claret. 1997. p. 118.

CHEN, Y.; ZHANG, G. A Pan-Sharpening Method Based on Evolutionary Optimization and IHS Transformation. **Mathematical Problems in Engineerin**, [S.l.], v. 2017, Oct. 2017. Disponível em: <<https://doi.org/10.1155/2017/8269078>>. Acesso em 01 jun. 2020.

CICERELLI, R. E.; GALO, M. L. B. T. Sensoriamento remoto multifonte aplicado na detecção do fitoplâncton em águas interiores. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 19, p. 259-265, 2015.

CIRILO, J. A.; ALVES, F. H. B.; SILVA, B. M.; CAMPOS, P. H. A. L. Pernambuco Tridimensional: base de dados espaciais para planejamento urbano e gestão territorial. In: SIMPÓSIO DE HIDRÁULICA E RECURSOS HÍDRICOS DOS PAÍSES DE LÍNGUA PORTUGUESA, 12., 2015, Brasília. **Anais...** Lisboa, Portugal: Associação Portuguesa de Recursos Hídricos, 2015. v. 1. p. 81-100.

COLAÇO, A. F.; TREVISAN, R. G.; EITELWEIN, M. T.; MOLIN, J. P. Sensor LiDAR (Light detection and ranging) para obtenção de modelos tridimensionais de culturas de porte arbóreo. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 10., 2015, Ponta Grossa. **Anais...** Ponta Grossa: SBIAgro, 2015. Disponível em:

<<http://eventos.uepg.br/sbiagro/2015/anais/SBIAgro2015/index.htm>>. Acesso em 05 nov. 2019. ISBN 978-85-69929-00-0.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 136 p.

COSTA, E. R.; SILVA, M. A. O.; P. E.; MACHADO; SILVA, A. J. F. Orto-retificação: um passo a mais no processamento de imagens CBERS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007.

CRÓSTA, A. P. **Processamento digital de imagens de Sensoriamento Remoto**. Campinas: UNI-CAMP, 1992. 171 p.

\_\_\_\_\_. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: IG/UNICAMP, 1993. 170 p.

CRUZ, F. N.; BORBA, G. L.; ABREU, L. R. D. de. **Ciências da natureza e realidade: interdisciplinar**. Natal: Editora da UFRN (EDUFRN), 2005. 348 p.

DAMASCENO, M. Introdução a Mineração de Dados Utilizando o Weka, Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, 2005.

DANTAS, C. E. D. **Previsão e Controle de Inundações Em Meio Urbano Com Suporte de Informações Espaciais de Alta Resolução**. 2012. 221 f. Tese (Doutorado em Engenharia Civil)- Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Recife, 2012.

DEFINIENS. **Definiens eCognition Developer 8 (Reference book)**. München: Definiens AG, Trappentreustr, 2009. 276 p.

\_\_\_\_\_. **eCognition Developer for Windows operating system (Reference book)**. München: Trimble Germany GmbH, 2019. 521 p.

DEKKER, R. J. Texture analysis and classification of ERS SAR images for map updating of urban areas in The Netherlands. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 41, n. 9, p. 1950-1958, 2003.

DELL'ACQUA, F.; GAMBA, P. Texture-based characterization of urban environments on satellite SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 41, n. 1, p. 153-159, 2003.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz Do Rio Pardo – SP usando imagens LANDSAT-5. **RA'EGA**, Curitiba, v. 21, p. 234-271, 2011.

DI MAIO, A. RUDORFF, B. F. T.; MORAES, E. C.; PEREIRA, G.; MOREIRA, A. A.; SAUSEN, T. M.; FLORENZANO, T. G. **Formação Continuada de Professores: Sensoriamento Remoto**. Brasília: AEB, 2008. 82 p. (Apostila AEB Escola) (Manual de Instrumentação).

EHLERSA, M.; KLONUSA, S.; ÅSTRANDB, P. J.; ROSSOA, P. Multi-sensor image fusion for pansharpening in remote sensing. **Int. J. Image Data Fusion**, [S.l.], v. 1, n. 1, p. 25–45. Fev. 2010. Disponível em: <<https://doi.org/10.1080/19479830903561985>>. Acesso em 01 jun. 2020.

EJAILY, A. E.; ELTOHAMY, F.; NAHAS, M.Y. E.; ISMAIL, G. A. New Image Fusion Technique to Improve the Quality of Remote Sensing images. **International Journal of Computer Science Issues**, [S.l.], v. 10, n. 3, p. 565-569, 2013.

EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA TERRITORIAL. **CBERS**: China-Brazil Earth Resources Satellite ou Satélite Sino-Brasileiro de Recursos Terrestres. EMBRAPA Territorial: Campinas, 2014. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/cbers>>. Acesso em 04 nov. 2019.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.

ERBEK, F. S.; ÖZKAN, C.; TABERNER, M. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. **International Journal of Remote Sensing**, [S.l.], v. 25, n. 9, p. 1733-1748, May 2004.

ESPÍNDOLA, G.M. **Ajuste dos parâmetros de algoritmos de segmentação de imagens por crescimento de regiões**. 2006. 65 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.

ESQUEF, I. A.; ALBUQUERQUE, M. P. de; ALBUQUERQUE, M. P. de. **Processamento Digital de Imagens**. Urca, Rio de Janeiro: Centro Brasileiro de Pesquisas Físicas, 2003. 12 p. Disponível em: <<http://www.cbpf.br/cat/pdsi/pdf/cap3webfinal.pdf>>. Acesso em 06 nov. 2019.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases AI Magazine. **American Association for Artificial Intelligence**, Califórnia, USA, v. 17, n. 3, p. 37-54, 1996.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. UTHURUSAMY, R. (Ed.). **Advances in Knowledge Discovery and Data Mining**. Cambridge: MIT Press, 1996.

FERNANDESA, F. T.; CHIAVEGATTO FILHO, A. D. P. Perspectivas do uso de mineração de dados e aprendizado de máquina em saúde e segurança no trabalho. **Revista Brasileira de Saúde Ocupacional**, São Paulo, v. 44, n. 13, nov., 2019.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, Brasília, v. 35, n. 1, p. 25-30, jan./abr. 2006.

FERRO, L.; STURARO, J. R. Aplicação da rede neural MLP (Multilayer Perceptron) em indústria de pisos e revestimentos do polo cerâmico de Santa Gertrudes-SP. **Revista Geociências**, São Paulo, v.32, n.4, p.706-714, 2013.

FIDALGO, E. C. C.; COELHO, M. R.; ARAUJO, F. de O.; SANTOS, H. G. dos; BREFIN, M. de L. M. S. Uso de imagens de satélite para o estudo do uso da terra e sua dinâmica. In: MOREIRA, F. M. S.; CARES, J. E.; ZANETTI, R.; STUMER, S. L. (Ed.). **O ecossistema solo: componentes, relações ecológicas e efeitos na produção vegetal**. Lavras: UFLA, 2013. cap. 2, p. 32-43.

FIGUEIRÊDO, A. de C.; MONTENEGRO, A. A. de A.; SANTOS, E. S. dos; GUERRA, S. M. S.; VILLAR, A. C.; GUSMÃO, L. Determinação de Índices de Vegetação para a análise da cobertura vegetal em bacia hidrográfica do Agreste Pernambucano. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 15., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 7009-7015.

FLEISS, J. L. **Statistical methods for rates and proportions**. New York: John Wiley; 1981. p. 212-236.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de Textos, 2011.

FRANCISCO, C. N.; ALMEIDA, C. M. de. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. **Bol. Ciênc. Geod.**, sec. Artigos, Curitiba, v. 18, n. 2, p.302-326, abr./jun. 2012.

FREIRE, N. C. F. Reserva Biológica Serra Negra. In: FREIRE, N. C. F.; MOURA, D. C.; SILVA, J. B.; MOURA, A. S. S. (Org.). **Mapeamento e Análise Espectro-Temporal das Unidades de Conservação de Proteção Integral da Administração Federal no Bioma Caatinga**. Recife: Fundação Joaquim Nabuco; Campina Grande: UFCG, 2017. cap. 17, pag. 1-27. (Relatório Parcial da Pesquisa).

FREITAS, N. C. A.; MOURA, C. D. G.; SILVA, M. P. S. Sistema multiagente para mineração de imagens de satélite. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** João Pessoa: INPE, p. 7351- 7358, 2015.

FULLER, O. D. Forest fragmentation in Loudoun Country, Virginia, USA evaluated with multitemporal LANDSAT imagery. **Landscape Ecology**, v. 16, p. 627-642, 2001.

FURTADO, L. F. de A.; FRANCISCO, C. N.; ALMEIDA, C. M. Análise de imagem baseada em objeto para classificação das fisionomias da vegetação em imagens de alta resolução espacial. **Geociências**, UNESP, São Paulo, v. 32, n. 3, p. 441-451, 2013.

GALANTE, M. L V.; BESERRA, M. M. L.; MENEZES, E. O. **Roteiro Metodológico de Planejamento: Parque Nacional, Reserva Biológica, Estação Ecológica**. Brasília: IBAMA, 2002, p. 136.

GALVÍNCIO, J. D.; PEREIRA, J. A. S.; FRANÇA, L. M. A.; LINS, T. M. P. Análise da variação da vegetação dos períodos secos e chuvosos através do SAVI e albedo de superfície no município de Belo Jardim – PE. **Revista Rede Eletrônica do PRODEMA - REDE**, Fortaleza, v. 10, n. 2, p. 133-146, jul./ago., 2016.

GAROFALO, D. F. T.; MESSIAS, C. G.; LIESENBERG, V.; BOLFE, É. L.; FERREIRA, M. C. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. **Pesquisa Agropecuária Brasileira**, Brasília, v. 50, n. 7, July, 2015.

GERMAN, G. W. H.; GAHEGAN, M. N. Neural Network Architectures for the Classification of Temporal Image Sequences. **Computers e Geosciences**, [S.l.], v. 22, n. 9, p. 969-979, 1996.

GOMES, P. B.; BOLFE, É. L.; SPINELLI-ARAUJO, L.; VICTORIA, D. de C.; GARRASTAZU, M. C. Classificação de florestas naturais e plantadas no bioma Pampa com imagens de satélite multi-sensor e análise orientada a objeto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** João Pessoa: INPE, 2015.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. São Paulo: Editora Pearson Prentice Hall, 2010. 624 p.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Ed. Edgard Blücher, 2000. 509 p.

GUILLOU, A. N. **Análise de bordas de reservatório utilizando múltiplos sensores**: estudo de caso: reservatório de Itaparica-PE. 2016. 60 f. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação) – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, Recife, 2016.

GUIMARÃES, C. C. J.; MACHADO, S. F.; BORGES, C. A. L.; REZENDE, P. L. J.; SOARES, V. A. A.; SANTOS, A. A. Espectos legais no entorno das unidades de conservação brasileira: Área circundante e Zona de Amortecimento em face a resolução do CONAMA N° 428/2010. **Espaço e Geografia**, Brasília, v. 15, n. 1, 2012. ISSN:1516-9375

GUIMARÃES, L. M.; CANDEIAS, A. L. B. Utilização de técnicas de processamento de imagens digitais para definição de contorno de reservatórios. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** Natal: INPE, 2009. p. 6927-6934.

HARALICK, R. M; SHANMUGAM, K; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, [S.l.], v. 3, p. 610-620, 1973.

HAYKIN, S. **Redes Neurais**: Princípios e Práticas. Porto Alegre: Bookman, 2001. 900 p.

HUDSON, W. D.; RAMM, C. W. Correct formulation of the kappa coeff of agreement. **Remote Sensing Brief**, [S.l.], v. 53, n. 4, p. 421-422, Apr. 1987.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, 25, n. 3, p. 295-309, 1988. Disponível em: <[http://dx.doi.org/10.1016/0034-4257\(88\)90106-X](http://dx.doi.org/10.1016/0034-4257(88)90106-X)>. Acesso em 10 set. 2020.

IBAMA - Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Unidades de Conservação do Brasil**: parques nacionais e reservas biológicas. Brasília: Ministério do Interior, 1989.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Bases e referenciais**. Rio de Janeiro: IBGE, 2015; 2018. Vários mapas. Escalas variam. Disponível em: <<https://mapas.ibge.gov.br>>. Acesso em: 20 de jan. de 2020.

\_\_\_\_\_. **Malhas Territoriais.** Brasília: IBGE, 2020. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais.html>. Acesso em 10 abr. 2020.

INPE - Instituto Nacional de Pesquisas Espaciais. **Divisão de Geração de Imagens: LANDSAT.** José dos Campos: INPE, 2016. Disponível em: <http://www.dsr.inpe.br/DSR/areas-de-atuacao/sensores-plataformas>. Acesso em 05 nov. 2019.

\_\_\_\_\_. **Divisão de Sensoriamento Remoto: Sensores e Plataforma LIDAR.** São José dos Campos: INPE, 2017. Disponível em: <http://www.dsr.inpe.br/DSR/areas-de-atuacao/sensores-plataformas>. Acesso em 05 nov. 2019.

\_\_\_\_\_. **Aplicação ao Sensoriamento Remoto (SER 204).** São José dos Campos: INPE, 2020. Disponível em: <http://www.dpi.inpe.br/~camilo/estatistica/aulas.html>. Acesso em: 10 set. 2020.

\_\_\_\_\_. **Introdução ao sensoriamento remoto histórico.** São José dos Campos: INPE, 1998. (Projeto EDUCA Serie I) (Cadernos Didático n° 2).

\_\_\_\_\_. **Manual do Spring: Noções de Geoprocessamento.** São José dos Campos: INPE, 1997.

INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Satélite Sino-Brasileiro de Recursos Terrestres (CBERS).** São José dos Campos: INPE, 2018. Disponível em: <http://www.cbears.inpe.br/>. Acesso em 04 nov. 2019.

IQBAL, M. **An introduction to solar radiation.** New York: Academic Press, 1983. 212p.

ITO, R. H.; KIM, H. Y.; SALCEDO, W. J. **Classificação de Texturas Invariante a Rotação Usando Matriz de Co-ocorrência.** [S.l.: S.n.], 2011. Disponível em: <http://www.lps.usp.br/~hae/Ito-Kim-Salcedo-Textura.pdf>. Acesso em 08 abr. 2021.

JACKSON, P. **Introduction to Expert Systems.** Boston: Addison-Wesley, 1986.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres.** São José dos Campos: Parêntese, 2009.

JENSEN, J. R.; EPIPHANIO, J. C. N. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres.** São José dos Campos: Parêntese, 2011. 598 p.

KORTING, T. S. FONSECA, L. M. G. ESCADA, M. I. S.; CÂMARA, G. GeoDMA: Um sistema para mineração de dados de sensoriamento remoto. In.: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7813-7820

KOVÁSC, Z. L. **Redes Neurais Artificiais.** São Paulo: Editora Livraria da Física, 2002. 180 p.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, Pequim, v. 7, n. 1, p. 3-10, 2016.

LEAL, J. de M.; MELLO, J. G. **Bacia Sedimentar do Jatobá - PE: estudo hidrogeológico**. Recife: SUDENE, 1983. 236 p. (Série Hidrogeologia, 64).

LEITE, A. C. de S.; SENA, F. T. N. de S.; SANTIAGO NETO, B. J. Técnicas de sensoriamento remoto na análise temporal para a gestão territorial do município de Timon - MA. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 4., 2012, Recife. **Anais...** Recife: SIMGEO; UFPE, 2012. p. 126–136.

LEONARDI, F. **Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano**. 2010. 134 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.

LI, J. CARLSON, B. E. LACIS, A. A. Application of spectral analysis techniques in the inter-comparison of aerosol data, Part 4: Synthesized analysis of multisensor satellite and ground-based AOD measurements using combined maximum covariance analysis. **Atmos. Meas. Tech.**, Alemanha, v. 7, p. 2531-2549, 2014.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. New York: John Wiley and Sons, 2004. 763 p.

LINS, T. de S. **Controle de qualidade de dados de MDT adquirido por perfilamento a laser**. 2018. 81 f. Trabalho de Conclusão de Curso (Graduação) – Universidade Federal de Pernambuco. Centro de Tecnologia e Geociências, Departamento de Engenharia Cartográfica, Recife, 2018.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. UNIDERP, 2007, 908 p.

LOPES, R. J. de C.; SANTOS, A. M. dos; ZLATAR, T.; LIMA JÚNIOR, C. Uso de índices de vegetação por sensoriamento remoto para estudos da Caatinga: uma revisão sistemática. **Gaia Scientia**, João Pessoa, v. 14, n. 1, p. 104-116, 2020.

LUZ, N. B. da; SANTOS, D. J. dos; ANTUNES, A. F. B. Segmentação de imagens e classificação baseada em regras de conhecimento como novas abordagens para o mapeamento do uso da terra no Estado do Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 14., 2009, Natal. **Anais...** Natal: INPE, 2011, p. 989-996. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr%4080/2008/11.17.18.19/doc/989-996.pdf>>. Acesso em 07 nov. 2019.

MACHADO, C. C. C. **Alterações na superfície do Parque Nacional do Catimbau (PEBrasil): consolidação dos aspectos biofísicos na definição dos indicadores ambientais do bioma Caatinga**. 2014. 221 f. Tese (Doutorado em Geografia) Universidade Federal de Pernambuco, Programa de Pós-Graduação em Ciência Geográficas, Recife, 2014.

MAGALHÃES, I. A. L.; XAVIER, A. C. Caracterização e avaliação das respostas espectrais de alvos no município de Itapemirim - ES, por meio de sensoriamento remoto orbital. **Revista Brasileira de Geografia Física**, Recife, v. 11, n. 3, p. 1010-1025, 2018.

MAGALHÃES, I. A. L.; XAVIER, A. C.; SANTOS, A. R. Caracterização da dinâmica espectro temporal florestal e da cana-de-açúcar no município de Itapemirim, ES. **Revista Geosul**, Florianópolis, v. 28, p. 183-210, 2013.

MANDANICI, E.; BITELLI, G. Multi-Image and Multi-Sensor Change Detection for Long-Term Monitoring of Arid Environments With LANDSAT Series. **Remote Sensing**, [S.l.], v. 7, n. 10, p. 14019-14038, Oct. 2015. Disponível em: <<https://doi.org/10.3390/rs71014019>>. Acesso em 07 nov. 2019.

MARTINS, V. S.; SOARES, J. V.; NOVO, E. M. L. M.; BARBOSA, C. C. F.; PINTO, C. T.; ARCANJO, J. S.; KALEITA, A. Continental-scale surface reflectance product from CBERS-4 MUX data: Assessment of atmospheric correction method using coincident Landsat observations. **Remote Sensing of Environment**, [S.l.], v. 218, p. 55–68, 2018.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in nervous activity. **Bulletin of Mathematical Biophysics**, [S.l.], v. 5, n. 1, p. 115-133, 1943.

MELLO, C. E. R.; SILVA, G. Z.; SOUZA, J. M. Extensão do WEKA para Métodos de Agrupamento com Restrição de Contiguidade. In: BRAZILIAN SYMPOSIUM ON GEOINFORMATICS, 9., 2007, Campos do Jordão, **Anais...** Campos do Jordão: INPE, 2007, p. 277-282.

MENDES, T. S. G.; DAL POZ, A. P. Classificação de imagens aéreas de alta-resolução utilizando Redes Neurais Artificiais e dados de varredura a laser. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 15., 2011, Curitiba. **Anais...** Curitiba: INPE, 2011. p. 7792- 7799.

MENESES, P. R.; ALMEIDA, T. de. (Orgs). **Introdução ao Processamento de imagens de sensoriamento remoto**. Brasília: UNB, 2012.

MHANGARA, P.; MAPURISA, W.; MUDAU, N. Comparison of Image Fusion Techniques Using Satellite Pour l' Observation de la Terre (SPOT) 6 Satellite Imagery. **Applied Sciences**, [S.l.], v. 10, n. 5, 1881, 2020.

MMA - Ministério do Meio Ambiente. **Avaliação e ações prioritárias para a conservação da biodiversidade da Mata Atlântica e Campos Sulinos**: Conservation International do Brasil, Fundação SOS Mata Atlântica, Fundação Biodiversitas, Instituto de Pesquisas Ecológicas, Secretaria do Meio Ambiente do Estado de São Paulo, Instituto Estadual de Florestas - MG. Brasília: MMA/SBF, 2000. 40 p.

MOKHTARZADE, M.; ZOEJ, M. J. V. Road detection from high-resolution satellite images using artificial neural networks. **International Journal of Applied Earth Observation and Geoinformation**, [S.l.], v. 9, p. 32-40, 2007.

MORAES, E. C. **Fundamentos de Sensoriamento Remoto**. São José dos Campos: INPE, 2001. 22 p.

MORATO, R. G.; KAWAKUBO, F. S.; LUCHIARI, A. Avaliação da qualidade de vida urbana no município de Embu por meio de técnicas de geoprocessamento. **GEOUSP - Espaço e Tempo**, São Paulo, n. 23, p. 149-163, dez. 2008. Disponível em: <<http://www.revistas.usp.br/geosp/article/view/74086/77728>>. Acesso em 23 out. 2019.

MOREIRA, E. F.; SANTOS, R. L. da S.; FRANCA-ROCHA, W. de J. S. da; BOSCOLO, D.; PIGOZZO, C. M. Comparação e desempenho de algoritmos paramétricos na classificação supervisionada de áreas naturalmente heterogêneas e dinâmicas. **Revista Brasileira de Cartografia**, Rio de Janeiro, v.3, n. 68, p. 581-594, Mar./Abr., 2016.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. São José dos Campos: INPE, 2001.

NASA - National Aeronautics and Space Administration. **LANDSAT 7 science data users**. [S.l.], 1998. Disponível em: <[http://LANDSATHandbook.gsfc.nasa.gov/pdfs/LANDSAT7\\_Handbook.pdf](http://LANDSATHandbook.gsfc.nasa.gov/pdfs/LANDSAT7_Handbook.pdf)>. Acesso em 15 de set. 2020.

\_\_\_\_\_. **The LANDSAT program**. Washington, D.C., EUA: NASA, 2010; 2015. Disponível em: <<https://LANDSAT.gsfc.nasa.gov/>>. Acesso em 05 nov. 2019.

NASCIMENTO, E. F.; AZEVEDO, L. de S.; CANDEIAS, A. L. B. TAVARES JÚNIOR, J. R. Comparison of water index for MUX / CBERS-4 digital number and monochrome reflectance images. **Journal of Hyperspectral Remote Sensing**, v. 10, n.1, p. 34-44, 2020.

NASCIMENTO, S. S.; de LIMA, E. R. V.; de LIMA, P. P. S. Uso do NDVI na análise temporal da degradação da Caatinga na Sub-bacia do Alto Paraíba. **Revista OKARA: Geografia em debate**, João Pessoa, v. 8, n. 1, p. 72-93, 2014.

NAUE, C. R.; GALVÍNCIO, J. D.; MOURA, M. S. B. de; COSTA, V. S. de O. Resposta Espectral de Espécies da Caatinga. In: SIMPÓSIO DE MUDANÇAS CLIMÁTICAS E DESERTIFICAÇÃO NO SEMIÁRIDO BRASILEIRO, 3., 2011, Juazeiro. **Anais...** Petrolina: Embrapa Semiárido, 2011.

NAVULUR, K. **Multispectral image analysis using the object-oriented paradigm**. Davis: CRC, 2006. 184 p.

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

NEVES, L. Z.; MUCIDA, D. P. Comparação de índices de vegetação entre imagens CBERS, Landsat e Rapideye para área do Cerrado Brasileiro. **Revista Espinhaço**, Diamantina, v. 9, n. 1, p. 43-51, 2020.

NONATO, R. T.; OLIVEIRA, S. R. de M. Técnicas de mineração de dados para identificação de áreas com cana-de-açúcar em imagens LANDSAT - 5. **Eng. Agríc.**, Jaboticabal, v. 33, n. 6, p. 1268-1280, nov./dez. 2013.

NOVACK, T. **Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor QuickBird**. 2009. 214 f. (INPE-16594-TDI/1580). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2009. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/08.31.21.23>>. Acesso em 30 de jul. de 2020.

NOVO, E. M. L. de M.; PONZONI, F. J. **Introdução ao sensoriamento remoto**. São José dos Campos: INPE, 2001. 68 p.

NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Editora Edgard Bücher Ltda., 1992. 308 p.

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

OLIVEIRA, C. B. de S. **Análise da integração espacial de múltiplos sensores**. 2018. 61 f. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação) – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, Recife, 2018.

OLIVEIRA, J. S. e S. **Índices de vegetação (NDVI, IVAS, IAF, NDWI) como subsídio à gestão do uso e ocupação do solo na zona de amortecimento da reserva biológica de Saltinho, Pernambuco**. 2013. 91 f. Dissertação (Mestrado em Ciências Geográficas) - Universidade Federal de Pernambuco. Programa de Pós-Graduação em Geografia, Recife, 2013.

OLIVEIRA, S. N. de; CARVALHO JÚNIOR, O. A. de; GOMES, R. A. T.; GUIMARÃES, R. F.; MARTINS, É. de S. Detecção de mudança do uso e cobertura da terra usando o método de pós-classificação na fronteira Agrícola do Oeste da Bahia sobre o grupo Urucuaia durante o período 1988-2011. **Revista Brasileira de Cartografia**, Rio de Janeiro, n. 66/5, p. 1157-1176, set./out. 2014. ISSN 1808-0936.

OSÓRIO, F. S. Redes Neurais Artificiais: do aprendizado natural ao aprendizado artificial. In.: Fórum de Inteligência Artificial 1., 1999, Canoas. **Resumos...** Canoas: ULBRA, 1999. Disponível em: <http://osorio.wait4.org/oldsite/IForumIA/fia99-ppt.pdf>. Acesso em: 05 de setembro de 2020.

OTB - ORFEO TOOLBOX. **The ORFEO Tool Box Software Guide Updated for OTB-6.6.1**. [S. l.]: OTB Development Team, 2018. Disponível em: <https://www.orfeo-toolbox.org/SoftwareGuide/index.html>. Acesso em 10 de jun. de 2020.

PACHECO, A. P.; FREIRE, N. C. F.; BORGES, U. da N. Contribuição do sensoriamento remoto para detecção de áreas de gradadas na Caatinga brasileira. **Boletim Goiano de Geografia**, Goiânia, v. 26, n. 1, p. 49-68, jan./jun. 2006.

PE3d - Pernambuco Tridimensional; PERNAMBUCO (Estado). Secretaria de Desenvolvimento Econômico. **Programa Pernambuco Tridimensional (PE3d)**. Recife, 2016. Disponível em: <http://www.pe3d.pe.gov.br/>. Acesso em 16 out. 2019.

PEDRASSOLI, J. C. **Análise Orientada a Objeto para detecção de favelas e classificação do uso do solo em Taboão da Serra/SP**. 2011. 114 f. Dissertação (Mestrado em Geografia Física) - Universidade de São Paulo, Programa de Pós-Graduação em Geografia Física, Departamento de Geografia da Faculdade de Filosofia, Letras e Ciências Humanas, São Paulo, 2011.

PEDREIRA, B. da C. C. G.; FIDALGO, E. C. C.; PRADO, R. B.; ARAÚJO, R. de S. Classificação digital de imagens de satélite de alta resolução espacial para o mapeamento de

uso e cobertura da terra na área do complexo petroquímico do Rio de Janeiro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 15., 2011, Curitiba. **Anais...** Curitiba: INPE, 2011, p. 7340-7347. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.26.17.02/doc/p0336.pdf>>. Acesso em 07 nov. 2019.

PEREIRA, G. H. de A.; CENTENO, J. A. S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e laser scanner. **Boletim de Ciências Geodésicas, Sec. Artigos**, Curitiba, v. 23, n. 2, p. 268-283, abr./jun. 2017. Disponível em: <<http://dx.doi.org/10.1590/S1982-21702017000200017>>. Acesso em 07 nov. 2019. ISSN 1982-2170.

PEREIRA, R. de C. R.; SILVA, J. A. da; BARBOSA, J. I. de S. FLORA DE UM “BREJO DE ALTITUDE” DE PERNAMBUCO: RESERVA ECOLÓGICA DA SERRA NEGRA. **Anais da Academia Pernambucana de Ciência Agrônômica**, Recife, v. 7, p.286-304, 2010.

PEREZ, R. Algoritmo Back-Propagation. **Revista Programar**, [S. l.], ed. 57, p. 16-19, jul. 2017. Disponível em: <https://www.revista-programar.info/artigos/algoritmo-back-propagation/>. Acesso em: 05 de setembro de 2020.

PIAZZA, G. A. **Processamento digital de imagens de alta resolução espacial com enfoque na classificação dos estágios sucessionais iniciais da Floresta Ombrófila Densa em Santa Catarina**. 2014. 127 f. Dissertação (Mestrado em Engenharia Ambiental) - Fundação Universidade Regional de Blumenau, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Ambiental, Blumenau, 2014.

PIAZZA, G. A.; VIBRANS, A. C. Classificação orientada a objetos para mapear florestas secundárias em Santa Catarina, Sul do Brasil. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 66, n. 5, p. 993-1005, set./out., 2014.

PIMENTA, A.; VALENTIM, P.; SANTOS, D.; NETO, M. WEKA-G: mineração de dados paralela em grades computacionais. **Revista de Sistemas de Informação da FSMA**, n. 4, p. 2-9, 2009.

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, p. 1-22, 2016. Doi: <https://doi.org/10.3390/rs8050405>.

PIRES, J. M., M. S. **Uso do LIDAR (Light Detection and Ranging) para estimação da altura de árvores em povoamentos de eucalipto**. 2005. 48 f. Tese (Doutorado em Magister Scientiae) - Universidade Federal de Viçosa, Programa de Pós-Graduação em Ciência Florestal, Viçosa, 2005.

POLONIO, V. D. **Índices de vegetação na mensuração do estoque de carbono em áreas com cana-de-açúcar**. 2015. 73 f. Dissertação (Mestrado em Agronomia: Energia na Agricultura). Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas de Botucatu, 2015.

PURIFICAÇÃO, N. R. S. da; SILVA, R. M. da. **Estudo de micro e nanobacias hidrográficas para subsidiar a implantação do conceito base zero em áreas rurais do Semiárido Nordeste**. 2017. 74 f. Trabalho de Conclusão de Curso (Graduação em Engenharia

Cartográfica e de Agrimensura) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Departamento de Engenharia Cartográfica, Recife, 2017.

RAUBER, T. W. **Redes neurais artificiais**. Vitória: UFES, 2005. 29 p.

REX, F. E.; KÄFER, P. S.; BREUNIG, F. M.; SPOHR, R. B.; SANTOS, R. S. Classificação supervisionada de copas de árvores em imagem de alta resolução espacial. **BIOFIX Scientific Journal**, [S.l.], v. 3, n. 2, p. 216-223, 2018. Disponível em: <dx.doi.org/10.5380/biofix.v3i2.59563>. Acesso em 08 nov. 2019.

RIBEIRO, E. P.; NOBREGA, R. S.; MOTA FILHO, F. de O.; MOREIRA, E. B. M. Estimativa dos índices de vegetação na detecção de mudanças ambientais na bacia hidrográfica do rio Pajeú. **Revista Geosul**, Florianópolis, v. 31, n. 62, p. 59-92, jul./ago., 2016.

RICHARDS, J.; JIA, X. **Remote Sensing Digital Image Analysis**. Berlin, Heidelberg: Springer-Verlag, 2006. 431 p.

RISSO, J.; RIZZI, R.; EPIPHANIO, R. D. V.; RUDORFF, B. F. T.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; FERNANDES, S. L. Potencialidade dos índices de vegetação EVI e NDVI dos produtos MODIS na separabilidade espectral de áreas de soja. In: SIMPÓSIO DE SENSORIAMENTO REMOTO (SBSR), 14., Natal – RN. **Anais...** São José dos Campos: INPE. p. 379 –386, 2009.

RODAL, M. J. N.; NASCIMENTO, L. M. do. Levantamento florístico da floresta serrana da reserva biológica de Serra Negra, microrregião de Itaparica, Pernambuco, Brasil. **Acta Botanica Brasilica**, São Paulo, v. 16, n. 4, Oct./Dec. 2002. ISSN 0102-3306. ISSN 1677-941X.

RODRIGUES T. C. S.; KUX H. J. H. Uso do *software* livre INTERIMAGE para a classificação orientada a objetos em área de expansão urbana na ilha do Maranhão. **Revista Brasileira de Cartografia**, Rio de Janeiro, n. 67(3), p. 493-506, maio/jun. 2015.

RODRIGUES, J. O.; ANDRADE, E.; TEIXEIRA, A. S.; SILVA, B. B. da. Sazonalidade de variáveis biofísicas em regiões semiáridas pelo emprego do sensoriamento remoto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 29, p. 452-465, 2009.

ROSSITER, D. G. **Technical Note**: Statistical methods for accuracy assesment of classified thematic maps. Enschede: International Institute for Geo-information Science e Earth Observation (ITC), 2004.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring Vegetation Systems in the Great Plains with ERTS. **Proceedings Third Earth Resources Technology Satellite-1 Symposium**, Greenbelt, 1973. p. 310-317.

RUIZ, L. F. C. **Uma abordagem de classificação da cobertura da terra em imagens obtidas por veículos aéreo não tripulado**. 2015. 103 f. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Porto Alegre, 2015.

RUIZ, L. F. C.; GUASSELLI, L. A.; TEN CATEN, A. Árvore de decisão e análise baseada em objetos na classificação de imagens com resolução espacial submétrica adquiridas por VANT.

**Boletim de Ciências Geodésicas, Sec. Artigos**, Curitiba, v. 23, n. 2, p. 252-267, abr./jun. 2017. Disponível em: <<http://dx.doi.org/10.1590/S1982-21702017000200016>>. Acesso em 06 nov. 2019. ISSN 1982-2170.

SANCHEZ, E. C. M. **Controle por Aprendizado Acelerado e Neuro-Fuzzy de Sistemas Servo – Hidráulicos de Alta Frequência**. 2009. 130 f. Dissertação (Mestrado em Engenharia Mecânica) – Pontifícia Universidade Católica, Rio de Janeiro, 2009.

SANTOS, J. G. dos. **Investigação metodológica de detecção de bordas de reservatório**. Estudo de caso: Reservatório de Sobradinho – BA. 2012. 103 f. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação) – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, Recife, 2012.

SANTOS, R. Conceitos de Mineração de Dados na Web. In: SIMPÓSIO BRASILEIRO DE SISTEMAS MULTIMÍDIA E WEB, 15., 2009, Fortaleza. **Anais...** Fortaleza: WebMedia, 2009. p. 81-124.

SANTOS, V. F. dos; POLIDORI, L.; SILVEIRA, O. F. M. da; FIGUEIREDO JR., A. G. de. Aplicação de dados multisensor (SAR e ETM<sup>+</sup>) no reconhecimento de padrões de uso e ocupação do solo em costas tropicais: Costa Amazônica, Amapá, Brasil. **Revista Brasileira de Geofísica**, São Paulo, v. 27, supl.1, 2009. ISSN 0102-261X. Disponível em: <<http://dx.doi.org/10.1590/S0102-261X2009000500004>>. Acesso em 07 nov. 2019.

SCHNEIDER, M. J.; BELLON, O. R. P.; ARAKI, H. Experimentos em fusão de imagens de alta resolução. **Boletim de Ciências Geodésicas, Sec. Artigos**, Curitiba, v. 9, n. 1, p. 75-88, 2003.

SHITH, A. Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm. **Journal of Spatial Science**, Perth, v. 55, n. 1, p. 69-79, Jan. 2010.

SILVA, A. A. da; OLIVEIRA, A. P. G. de; PARANHOS FILHO, A. C.; GRIGIO, A. M. **Uso do eCognition 8 para classificação de imagem de satélite com alta resolução**. Mossoro: EDUERN, 2016. 107 p.

SILVA, C.; RALHA, C. Detecção de cartéis em licitações públicas com agentes de mineração de dados. **Revista Eletrônica de Sistemas de Informação**, v. 10, n. 1, 2011.

SILVA, D. V. S. da; CRUZ, C. B. M. Tipologias de Caatinga: Uma Revisão em Apoio a Mapeamentos Através de Sensoriamento Remoto Orbital e GEOBIA. **Revista do Departamento de Geografia**, São Paulo, v. 35, p. 113-120, 2018.

SILVA, F. M. M. da; ARAKI, H. Integração de dados de imagens orbitais de alta resolução e ALS para detecção semi-automática de edificações em áreas urbanas. **Boletim de Ciências Geodésicas, Sec. Artigos**, Curitiba, v. 21, n. 3, p. 548 - 571, jul./set. 2015. Disponível em: <<http://dx.doi.org/10.1590/S1982-21702015000300031>>. Acesso em 06 nov. 2019. ISSN 1982-2170.

SILVA, L. C. do N.; BACANI, V. M. Classificação orientada a objeto (GEOBIA) aplicada à análise das alterações do uso e cobertura da terra da Bacia Hidrográfica do Rio da Prata em Jardim e Bonito - MS. **Geografia**, Londrina, v. 26. n. 1. p. 05–18, jan./jun. 2017.

SILVA, L. G.; GALVÍNCIO, J. D. Análise comparativa da variação nos índices NDVI e SAVI no Sítio PELD – 22, em Petrolina – PE, na primeira década do século XXI. **Revista Brasileira de Geografia Física**, Recife, n. 6, p. 1446-1456, 2012.

SILVA, L. N. C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 1998. 210 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e Computação. Universidade Estadual de Campinas, Campinas, 1998.

SILVA, M. P. S. **Mineração de padrões de mudanças em imagens de sensoriamento remoto**. 2006. 128 f. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006. Disponível em: <<http://urlib.net/sid.inpe.br/MTC-m13@80/2006/02.14.17.12>>. Acesso em: 29 set. 2020.

SILVA, P. R. **Uso de Redes Neurais Artificiais e objetos geográficos na classificação digital de imagens de sensoriamento remoto**. 106 f. Dissertação (Mestrado em Manejo Florestal) - Universidade Federal Lavras, Programa de Pós-Graduação em Ciências Florestais, Lavras, 2012.

SILVA, R. de S.; PAES, Â. T. Por dentro da estatística - Teste de concordância Kappa. **Educ. Contin. Saúde Enstein**, [S.l.],v. 10, n. 4, p.165-166, 2012.

SILVA, R. M.; ALMEIDA, T. A.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v. 4, n. 2, p. 42-57, out. 2012.

SOARES, R. B.; SOARES, C. B. S. da S.; COSTA, J. A. L. da; COSTA, S. dos S.; SOARES, R. B. Aplicação de técnica de fusão em imagens LANDSAT 8/ OLI. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17., 2015, João Pessoa. **Anais...** João Pessoa: INPE, 2015. p. 4836- 4843.

SOTHE, C. **Classificação do estágio sucessional da vegetação em áreas de Floresta Ombrófila Mista empregando análise baseada em objeto e ortomagens**. 2015. 250 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade do Estado de Santa Catarina, Centro de Ciências Agroveterinárias, Programa de Pós-Graduação em Engenharia Florestal. Lages, SC, 2015.

SOUZA, D. M. Mapeamento e identificação das fitofisionomias no largo de Santa Rita – Santos/SP por meio das bandas do satélite World View-2. **Revista Acadêmica Oswaldo Cruz**, São Paulo, n. 8, ano 2., out/dez., 2015.

SPU - Secretaria do Patrimônio da União. **Sensoriamento Remoto**. [S.l.]: SPUGeo, 2017. (Apostila SPU: Sensoriamento Remoto).

TEDESCO, A. *et al.* Detecção de formação erosiva (voçoroca) por meio de classificação hierárquica e por árvore de decisão. **Bol. Ciênc. Geod.**, Curitiba, v. 20, n. 4, out./dez, 2014.

TOLENTINO, F. M. **Análise do desempenho de Redes Neurais Artificiais no monitoramento sazonal de Macrófitas no Reservatório de Salto Grande e nas mudanças no uso e cobertura da Terra do entorno**. 2019. 94 f. Dissertação (Mestrado em Ciências Cartográficas) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, Presidente Prudente, 2019.

TRIMBLE. **eCognition Developer 9.2** (Reference book). Munich: TRIMBLE Germany GmbH, 2016.

TU, T.; SU, S.; SHYU, H.; HUANG, P. S. Efficient intensity-hue-saturation-based image fusion with saturation compensation. **Optical Engineering**, [S.l.], v. 40, n. 5, p. 720-728, May 2001.

UCHÔA, E. B. CASTRO, N. A. Processamento Digital de Imagens: Análise em Componentes Principais – ACP(Técnica de Crósta) e Razão de Bandas LANDSAT – TM para Realçar Mármore e/ou Minerais Carbonáticos do Município de Independência – CE. **Revista de Geologia**, v. 24, n. 1, p. 28-35, 2011.

V. N. LIMA, M. F. O.; MELO, L. A.; ALCÂNTARA, L. L S.; FRANÇA, J. B.; PASSOS. Aquisição manual da categoria hidrografia com base em produtos do PE3d. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 7., 2018, Recife. **Anais...** Recife: SIMGEO; UFPE, 2018. p. 126–136.

VIANA, S. N. **Análise de Imagens do Satélite ALOS PALSAR para Discriminar Fitofisionomias do Bioma Cerrado: Estudo de Caso no Parque Nacional da Chapada dos Veadeiros**. 2012. 75 f. Dissertação (Mestrando em Geociências Aplicadas) - Instituto de Geociências, Departamento de Geologia Geral e Aplicada da Universidade de Brasília, Brasília, 2012.

WASHINGTON-ALLEN, R. A. W.; RAMSEY, R.D.; WEST, N. E. Spatiotemporal mapping of the dry season vegetation response of sagebrush steppe. **Community Ecology**, v. 5, n. 1, p. 69-79, 2004. <http://dx.doi.org/10.1556/ComEc.5.2004.1.7>.

WITTEN, I. H.; EIBE, F.; HALL, M. A. (3. Ed.). **DATA MINING**. Practical machine learning tools and techniques. Burlington, MA: Morgan Kaufmann, 2011. 665 p.

WITTEN, I. H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations**. (2. ed.). Burlington: Morgan Kaufmann Publishers, 2005.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, Oxford, v. 1, n. 1, p. 9-23, Jan. 2008.

YU, O.; GONG, P.; CLINTON, N.; BIGING, G.; KELLY, M.; SHIROKAUER, D. Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. **Photogrammetric Engineering and Remote Sensing**, [S.l.], v. 72, n. 7, p. 799-811, 2006.

ZACCHI, E. N. P.; SILVA, A. M.; ROLIM, V. K. Análise integrada de dados multifonte e sua aplicação no mapeamento geológico das formações ferríferas da Serra de Itapanhoacanga, Alvorada de Minas, MG. **Revista Brasileira de Geofísica**, [S.l.], v. 28, n. 4, p. 643-656, 2010. ISSN 0102-261X.

ZIOU, D.; TABBONE, S. Edge Detection Techniques: An Overview. **Patter Recognition and Image Analysis**, [S.l.], v. 8, n. 4, p. 1-41, 1998.