



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS

KHALIL ALI GANEM

**CLASSIFICAÇÃO DA COBERTURA DO SOLO NA CAATINGA A PARTIR DE
IMAGENS DO LANDSAT-8 E DA FERRAMENTA GOOGLE EARTH ENGINE: UMA
COMPARAÇÃO ENTRE DADOS COM E SEM CORREÇÃO ATMOSFÉRICA**

Dissertação de Mestrado nº 113

Área de Concentração: Geoprocessamento e Análise Ambiental

Brasília – DF

2017

KHALIL ALI GANEM

**CLASSIFICAÇÃO DA COBERTURA DO SOLO NA CAATINGA A PARTIR DE
IMAGENS DO LANDSAT-8 E DA FERRAMENTA GOOGLE EARTH ENGINE: UMA
COMPARAÇÃO ENTRE DADOS COM E SEM CORREÇÃO ATMOSFÉRICA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Mestre em Geociências Aplicadas, cuja área de concentração é Geoprocessamento e Análise Ambiental.

Prof. Dr. Gustavo Macedo de Mello Baptista

Orientador

Brasília – DF

2017

FICHA CATALOGRÁFICA

GANEM, Khalil Ali

Classificação da Cobertura do Solo na Caatinga a partir de Imagens do Landsat-8 e da Ferramenta *Google Earth Engine*: uma comparação entre dados com e sem correção atmosférica. Khalil Ali Ganem; orientação: Gustavo Macedo de Mello Baptista. – Brasília, 2017.

202p.

Dissertação de Mestrado nº 113 - Universidade de Brasília / Instituto de Geociências, 2017.

1. Caatinga; 2. *Google Earth Engine*; 3. Landsat-8; 4. Correção Atmosférica; 5. MapBiomias.

REFERÊNCIA BIBLIOGRÁFICA

GANEM, K. A. Classificação da Cobertura do Solo na Caatinga a partir de Imagens do Landsat-8 e da Ferramenta *Google Earth Engine*: uma comparação entre dados com e sem correção atmosférica. 2017. 182p. Dissertação de Mestrado – Instituto de Geociências, Universidade de Brasília, Brasília – Distrito Federal.

CESSÃO DE DIREITOS

NOME DO AUTOR: Khalil Ali Ganem

TÍTULO DA DISSERTAÇÃO: Classificação da Cobertura do Solo na Caatinga a partir de Imagens do Landsat-8 e da Ferramenta *Google Earth Engine*: uma comparação entre dados com e sem correção atmosférica.

GRAU: Mestre

ANO: 2017

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva-se a outros direitos de publicação e nenhuma parte desta dissertação pode ser reproduzida sem autorização por escrito do autor.

Khalil Ali Ganem

khalilganem@hotmail.com

KHALIL ALI GANEM

**CLASSIFICAÇÃO DA COBERTURA DO SOLO NA CAATINGA A PARTIR DE
IMAGENS DO LANDSAT-8 E DA FERRAMENTA GOOGLE EARTH ENGINE: UMA
COMPARAÇÃO ENTRE DADOS COM E SEM CORREÇÃO ATMOSFÉRICA**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Mestre em Geociências Aplicadas, cuja área de concentração é Geoprocessamento e Análise Ambiental.

06 de março de 2017

Prof. Dr. Gustavo Macedo de Mello Baptista (Presidente – UnB)

Prof. Dr. Washington de Jesus Sant'Anna da Franca Rocha (UEFS/BA)

Prof.^a Dra. Rejane Ennes Cicerelli (UnB)

DEDICATÓRIA

Este trabalho é inteiramente dedicado a três pessoas muito importantes na minha vida e que estiveram presente de corpo e alma durante toda a minha jornada no mestrado: Sofia Zagallo, Marcell Terra e Ohanna.

AGRADECIMENTOS

A Mãeceli e Sofia. Palavras são incapazes de expressar o tamanho da minha gratidão e o valor que a amizade de ambas representa na minha vida. Durante esses dois anos de mestrado, especialmente, vocês me complementaram de forma tão única e indissociável, que sem uma ou outra nada teria acontecido. Se eu fosse considerar todos os dias desses dois anos de mestrado, não existiu um dia sequer que uma ou outra não esteve comigo. Sofia me deu todo suporte para escrever, paz, tranquilidade de um lar, enquanto Mãeceli me ajudou com muita atividade braçal, passou umas noites lendo meu trabalho, me deu altas sugestões. E é por isso que esse trabalho não poderia ser dedicado a outras pessoas, senão vocês duas.

A Ohanna, por todo amor, palavras de carinho e apoio. A você dedico todo meu esforço. Um amor incondicional.

A Ilanna, por toda parceria e pela companhia intensa nos últimos dois meses de laboratório. Você não só me fez companhia como dividiu inúmeros sentimentos comigo. Sem falar nas inúmeras vezes que me acordou, que fez comer na hora certa ou simplesmente me fez rir por horas consecutivas com seu jeito único de ser. Você teve um papel muito importante, especialmente na reta final.

Ao meu professor e orientador Gustavo Baptista pela confiança e, especialmente, por todas as oportunidades que me deu ao longo da minha trajetória acadêmica.

A minha amiga Lilian. Sei que mesmo quando não pudemos nos encontrar você esteve comigo durante todo esse tempo. Sua amizade tem um valor especial para mim e sei o quanto se importou e se preocupou comigo. Muito obrigado.

Ao Marcos Rosa por toda paciência e auxílio para compreender e executar os *scripts* que geraram os dados presentes nesse trabalho. Você contribuiu significativamente para a qualidade dos meus dados e faço questão de tê-lo como parceiro em, no mínimo, todo o material que essa dissertação render.

Ao Rodrigo Vasconcelos, da UEFS. Obrigado por me dar suporte em tantos dias e horários que turbinei seu celular de mensagens com dúvidas e solicitações. Você abraçou essa causa junto comigo.

A Deorgia. Não teve uma vez que você não esteve do meu lado. Agradeço muito pela prestatividade que teve comigo durante toda a minha pesquisa. Não teve uma vez que não tenha me atendido ou estado disponível para me ajudar, responder minhas mensagens com tantas perguntas sobre a Caatinga. Muito obrigado. Você me deu uma aula sem saber.

A Carol e Débora pelas demonstrações de carinho e pela preocupação que tiveram comigo, mesmo as vezes eu estando a dias sem vê-las pessoalmente. Especialmente na reta final, vocês me deram muita força muitas mensagens de apoio.

Aos meus amigos do Laboratório de Sensoriamento Remoto e Análise Espacial – LSRAE, pelas companhias no almoço e no jantar, pelos lanches, pelas saídas e principalmente por compartilharem comigo experiências acadêmicas e por trazerem diversão durante todos dias e noites de pressão e correria. Muito obrigado Kellin, Diogo, Derlayne, Rodrigo, Mayara, Bruno Borges, Henrique, Kássia, Emmanuel e Fernando pela parceria.

Aos meus amigos do curso de Ciências Ambientais da UnB, Cíntia, Ryan e Jota, por acompanharem de perto e se preocuparem comigo durante esses dois anos de trabalho.

A Diego e Soltan, da UEFS, pelas dicas na validação dos pontos amostrais.

Agradecimento especial ao João Victor Siqueira, do MapBiomas, que contribuiu com diversas informações sobre o programa em si e os parâmetros para classificação utilizados pelo projeto.

Aos professores do Instituto de Geociências Brites, Edilson, Tati e George Sand pelos ensinamentos nas disciplinas.

Aos professores Washington Franca-Rocha e Rejane Ennes Cicerelli por aceitarem participar da minha banca.

A Luciana Coelho, Iona'i Moura e Mario Viggiano, que foram grandes referências profissionais para mim e os quais indiretamente exerceram uma forte contribuição para minha postura profissional.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pela concessão da bolsa de pesquisa que forneceu suporte à pesquisa desenvolvida.

“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo. Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas admiráveis”.
(José de Alencar).

RESUMO

O projeto intitulado Mapeamento Anual da Cobertura e Uso do Solo no Brasil - MapBiomias - é um projeto atual voltado para a classificação da cobertura do solo a nível nacional. As diversas classes abordadas no âmbito do projeto estão sendo identificadas e mapeadas com base em imagens das séries Landsat. Após a seleção de duas cartas, a SC-24-V-C e a SD-23-X-D, com base em critérios específicos, foi feito um comparativo entre o dado com correção atmosférica obtido por meio dos algoritmos FLAASH e QUAC, e o produto em reflectância no topo da atmosfera (LC8_L1T_TOA), sem correção atmosférica. Este último é o dado atualmente utilizado pelo MapBiomias para o Landsat-8 em classificações resultantes de uma árvore de decisão definida empiricamente pela equipe do projeto. Tal investigação se torna necessária pois o MapBiomias necessita obter um panorama acerca de qual dado apresenta o melhor ajuste às classificações, demonstrando-se mais realista ao contexto da Caatinga, o qual se trata do bioma proporcionalmente menos estudado dentre as regiões naturais brasileiras. As classificações foram geradas pelo *Code Editor* do *Google Earth Engine*, uma plataforma capaz de processar imagens de satélite na nuvem de forma distribuída e rápida, permitindo que ferramentas de alto desempenho interpretem e analisem uma gama de informações, as quais são visualizadas em mapas. A partir de análises visuais e da aplicação de testes estatísticos de exatidão global e por classe identificou-se o dado que melhor se ajustou ao contexto da Caatinga, nas cartas selecionadas, mostrando-se mais adequado para proceder com o mapeamento da cobertura do solo no bioma. A carta SC-24-V-C apresentou valores do coeficiente *Tau* para as classificações oriundas do dado sem correção atmosférica e com dados corrigidos pelo FLAASH e QUAC, de, respectivamente, 54,13%, 39,13% e 58,10%. Já a carta SD-23-X-D apresentou resultados para o mesmo índice de, respectivamente, 55,45%, 68,90% e 64,90%. Isso mostrou que o dado com correção atmosférica, de modo geral, mostrou melhor ajuste ao contexto da Caatinga em comparação com o dado em reflectância no topo da atmosfera. Além disso, dentre os dados utilizados, o FLAASH apresentou maior inconsistência, mostrando-se ora o melhor, ora o pior para cada carta, sendo ainda bem complexo para executar em comparação ao QUAC, que por sua vez é mais rápido no tempo de processamento e apresentou melhor desempenho. O dado sem correção atmosférica não demonstrou diferenças significativas em comparação com os dados corrigidos. E, apesar de ter sido mais baixo, mostrou resultados praticamente idênticos em ambas as análises, o que faz com que o dado não deva ser dispensado, devendo apenas ser feitos ajustes nos parâmetros da árvore de decisão para que seu uso seja mais eficiente. Apesar da variabilidade dos resultados estatísticos em função dos tipos de dados utilizados, constatou-se que a plataforma *Google Earth Engine* se demonstrou prática, rápida e satisfatória para proceder com a classificação da cobertura do solo na Caatinga.

Palavras-chave: Caatinga, *Google Earth Engine*, Landsat-8, Correção Atmosférica, MapBiomias.

ABSTRACT

The project entitled Mapping Annual Coverage and Land Use in Brazil - MapBiomias - is a current project focused on the classification of soil cover at a national level. The various classes addressed in the scope of the project are being identified and mapped based on Landsat images. After the selection of the SC-24-VC and SD-23-XD letters based on specific criteria, a comparison was made between the atmospheric correction data obtained using the FLAASH and QUAC algorithms, and the product of reflectance on the top of atmosphere (LC8_L1T_TOA), without atmospheric correction. The latter data is currently used by MapBiomias for Landsat-8 in the soil cover classifications based on a decision tree empirically defined by the project team. This is a necessary research because the MapBiomias project needs to obtain a panorama about which data represents the best adjustment to the classifications, proving to be more realistic to the context of the Caatinga, which is the biome proportionally less studied among the Brazilian natural regions. The classifications were generated by the Code Editor of Google Earth Engine, a platform capable of processing satellite images in the cloud in a distributed and fast way, allowing high performance tools to interpret and analyze a range of information, which is visualized in the form of maps. Based on the visual analysis and the application of statistical tests of global accuracy and accuracy by class, the data that best fit the context of the Caatinga was identified as the more appropriate to proceed with the mapping of the soil cover in the biome. The letter SC-24-V-C presented Tau values for the classifications from the TOA data and with data corrected by FLAASH and QUAC, of 54.13%, 39.13% and 58.10%, respectively. SD-23-X-D presented results for the same index of, respectively, 55.45%, 68.90% and 64.90%. This showed that the atmospheric correction data, in general, presented a better fit to the context of the Caatinga compared to the top-of-atmosphere reflectance data. In addition, among the data used, FLAASH presented a greater inconsistency, showing to be sometimes the best and in other times the worst for each image. And it is still quite complex to be used if compared to QUAC, which is faster in processing time and had a better performance. The data without atmospheric correction did not show significant differences in comparison with the corrected data. And, even though it had lower values, it showed almost identical results in both analysis, which means that the data should not be dispensed, being necessary only adjustments in the decision tree parameters to achieve more efficient results. In the end, despite the variability of the data, it was found that Google Earth Engine is a highly effective tool to proceed with the classification of the ground cover.

Keywords: *Caatinga, Google Earth Engine, Landsat-8, Atmospheric Correction, MapBiomias.*

LISTA DE ILUSTRAÇÕES

Figura 1 - Plataforma <i>Code Editor</i> do <i>Google Earth Engine</i> e suas principais finalidades.	35
Figura 2 - Design do projeto MapBiomias na internet	36
Figura 3 - Mapa do bioma Caatinga, indicando os estados sob seu domínio e o grau de abrangência do bioma em relação à área total de cada estado	38
Figura 4 - Fatores que influenciam na radiância em um sensor orbital	46
Figura 5 - – Comportamento espectral característico da vegetação nos comprimentos de onda do visível e infravermelho próximo e de ondas curtas .	51
Figura 6 - Janelas Atmosféricas mais importantes	57
Figura 8 - Estrutura de uma Matriz de Confusão.	71
Figura 9 - Fluxograma Metodológico do MapBiomias adaptado para o presente estudo	82
Figura 10 - Fluxograma detalhando os processamentos realizados para a correção atmosférica dos dados, seu papel dentro da metodologia do MapBiomias e as ferramentas utilizadas para produzir cada dado.	83
Figura 11 - Distribuição das cartas na escala de 1:250.000 por Bioma	84
Figura 12 - Mapa com as cartas internacionais do mundo ao milionésimo na escala de 1:250.000 que encobrem a Caatinga.	85
Figura 13 - Mapa das estações meteorológicas na Caatinga	86
Figura 14 - Mapas de 2013, 2014, 2015 e 2016 com a avaliação dos mosaicos do bioma Caatinga.	88
Figura 15 - Mosaico de imagens Landsat-8 da Carta SC-24-V-C para o ano de 2013.	90
Figura 16 - Mapa de Referência da vegetação a carta SC-24-V-C.	91
Figura 17 - Mosaico Temporal de imagens Landsat-8 da Carta SD-23-X-D para o ano de 2015.	92
Figura 18 - Mapa de Referência da vegetação a carta SD-23-X-D.	93
Figura 19 - Comparação entre uma imagem e um mosaico temporal após aplicação do filtro de mediana. Fonte: MapBiomias, 2015	96
Figura 20 - Biblioteca Espectral para quatro componentes puros, em reflectância de superfície e no topo da atmosfera.....	111

Figura 21 - Árvore de Decisão utilizada para parametrizar a classificação da cobertura do solo das cartas da Caatinga	114
Figura 22 - Distribuição aleatória dos pontos na carta SC-24-V-C para criar a verdade de campo (referência)	120
Figura 23 - Distribuição aleatória dos pontos na carta SD-23-X-D para criar a verdade de campo (referência)	121
Figura 24 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado em reflectância no topo da atmosfera (aparente) do dado LC8_L1T_TOA processado pelo Google Earth Engine....	124
Figura 25 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado com correção atmosférica a partir do QUAC	127
Figura 26 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado com correção atmosférica a partir do FLAASH	130
Figura 27 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado em reflectância no topo da atmosfera (aparente) processado pelo Google Earth Engine	133
Figura 28 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado com correção atmosférica a partir do QUAC	135
Figura 29 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado com correção atmosférica a partir do FLAASH	138
Figura 30 - Evolução temporal (2013-2016) do dado TOA (topo da atmosfera) da carta SC-24-V-C.....	147
Figura 31 - Evolução temporal (2013-2016) do dado QUAC da carta SC-24-V-C..	148
Figura 32 - Evolução temporal (2013-2016) do dado FLAASH da carta SC-24-V-C.	148
Figura 33 - Evolução temporal (2013-2016) do dado TOA (topo da atmosfera) da carta SD-23-X-D.....	149
Figura 34 - Evolução temporal (2013-2016) do dado QUAC da carta SD-23-X-D..	149
Figura 35 - Evolução temporal (2013-2016) do dado FLAASH da carta SD-23-X-.	150

LISTA DE TABELAS

Tabela 1 - Principais definições do termo sensoriamento remoto	42
Tabela 2 - Quantidades de vapor d'água na coluna de ar atmosférico e temperaturas do ar de superfície para os modelos atmosféricos do MODTRAN	64
Tabela 3 - Seleção do Modelo Atmosférico baseado na dependência Latitudinal/Sazonal da temperatura da superfície	64
Tabela 4 - Qualidade da classificação associada ao índice <i>Kappa</i>	75
Tabela 5 - Parâmetros considerados para a geração do mosaico temporal para cada ano de cada carta	94
Tabela 6 - valores utilizados para conversão dos dados de números digitais para radiância no topo da atmosfera.....	98
Tabela 7 - Bandas do OLI e os seus respectivos comprimentos de onda central e largura a meia altura	100
Tabela 8 - Conversão de unidades e seus fatores de escala correspondentes para inserção no FLAASH.....	101
Tabela 9 - Informações correspondentes a data, hora, elevação e azimute das cartas utilizadas	103
Tabela 10 - Valores considerados para o cálculo da visibilidade do FLAASH.....	107
Tabela 11 - Taxa de CO ₂ utilizada para cada ano processado no FLAASH.....	109
Tabela 12 - Demais parâmetros mantidos para o FLAASH (<i>Default</i>)	109
Tabela 13 - Caracterização das Classes de Cobertura do Solo Mapeadas	113
Tabela 14 - Valores adotados para cada parâmetro da Árvore de Decisão	114
Tabela 15 - Valores da amostragem mínima indicada para cada carta a ser avaliada com destaque para o maior valor encontrado.....	119
Tabela 16 - Matriz de Confusão da classificação oriunda a partir do produto LC8_L1T_TOA para a carta SC-24-V-C do ano de 2013	125
Tabela 17 - Matriz de Confusão da classificação oriunda a partir dos dados com correção atmosférica gerados pelo QUAC	128
Tabela 18 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo FLAASH	131
Tabela 19 - Matriz de Confusão da classificação oriunda a partir do produto LC8_L1T_TOA para a carta SD-23-X-D do ano de 2015	134

Tabela 20 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo QUAC	136
Tabela 21 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo FLAASH	139
Tabela 22 - Coeficientes de concordância globais para cada método calculados para cada carta da Caatinga	141
Tabela 23 - Exatidão do Produtor de cada classe dos métodos de classificação de cada carta	142
Tabela 24 - Exatidão do Usuário de cada classe dos métodos de classificação de cada carta	143
Tabela 25 - <i>Kappa</i> Condicional de cada classe dos métodos de classificação de cada carta	144
Tabela 26 - Parâmetros de visibilidade utilizados como dado de entrada antes de proceder o FLAASH e resultado após correção atmosférica	153

LISTA DE SIGLAS

AERONET – *Aerosol Robotic Network*
AOD – *Aerosol Optical Depth*
ASPRS – *American Society of Photogrammetry and Remote Sensing*
ASCII – *American Standard Code for Information Interchange*
ASTER – *Advanced Spaceborne Thermal Emission and Reflection Radiometer*
AVIRIS – *Airborne Visible/Infrared Imaging Spectrometer*
BIL – *Band Interleaved by Line*
BIP – *Band Interleaved by Pixel*
BSQ – *Band Sequential*
Bsh – *Clima semiárido quente*
Bshw – *Clima semiárido quente com chuvas de verão*
BV – *Brightness Value*
CAR – *Cadastro Ambiental Rural*
DN – *Digital Number*
ENVI – *ENvironment for Visualizing Images*
ETM+ – *Enhanced Thematic Mapper Plus*
EROS – *Earth Resources Observation Systems*
ERTS – *Earth Resource Technology Satellite*
FLAASH – *Fast Line-of-sight Atmospheric Analysis of Hypercubes*
FMASK – *Function of MASK*
FORTRAN – *Formula Translation System*
FWHM – *Full Width at Half Maximum*
GEE – *Google Earth Engine*
GV – *Green Vegetation*
IAF – *Índice de Área Foliar*
IARR – *Internal Average Relative Reflectance*
IBGE – *Instituto Brasileiro de Geografia e Estatística*
IDL – *Interactive Data Language*
IML – *Inverno de Média Latitude*
INPE – *Instituto Nacional de Pesquisas Espaciais*
IPCC – *Intergovernmental Panel on Climate Change*
ISA – *Inverno Subártico*
K – *Índice Kappa*
LIDAR – *Light Detection And Ranging*
MapBiomass – *Mapeamento Anual da Cobertura e Uso do Solo no Brasil*
MCTI – *Ministério da Ciência, Tecnologia e Inovação*
MeASURES – *Making Earth System Data Records for Use in Research Environments*

MEM – Modelagem Espectral de Mistura
MMA – Ministério do Meio Ambiente
MODIS – *Moderate Resolution Imaging Spectroradiometer*
MODTRAN – *MODerate resolution atmospheric TRANsmission*
MSS – *Multispectral Scanner System*
MTL – Metadado
NASA – *National Aeronautics & Space Administration*
ND – Números Digitais
NDFI – *Normalized Difference Fraction Index*
NDMI – *Normalized Difference Moisture Index*
NDSI – *Normalized Difference Snow Index*
NDVI – *Normalized Difference Vegetation Index*
NDWI – *Normalized Difference Water Index*
NPV – *Nonphotosynthetic Vegetation*
NOAA – *National Oceanic and Atmospheric Administration*
OC – Observatório do Clima
OLI – *Operational Land Imager*
ONR – *Office of Naval Research*
PaaS – *Platform as a Service*
PDI – Processamento Digital de Imagens
Pixel – *Picture Element*
PROBIO – Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira
QUAC – *QUick Atmospheric Correction*
REM – Radiação Eletromagnética
RMSE – *Root Mean Square Error*
RSI – *Research Systems Inc.*
SAVI – *Soil Adjusted Vegetation Index*
SIG – Sistema de Informação Geográfica
SMA – *Spectral Mixture Analysis*
SEEG – Sistema de Estimativas de Emissões de Gases de Efeito Estufa
SEEG/OC – Sistema de Estimativas de Emissões de Gases de Efeito Estufa / Observatório do Clima
SKYLAB – *Sky Laboratory*
SPOT – *Satellite Pour l'Observation de la Terre*
SRTM – *Shuttle Radar Topography Mission*
SWIR – *Short-wave Infrared*
TIFF – *Tagged Image File Format*
TIROS – *Television Infrared Observation Satellite*
TIRS – *Thermal Infrared Sensor*
TM – *Thematic Mapper*
TOA – *Top Of Atmosphere*

UEFS – Universidade Estadual de Feira de Santana

USGS – *United States Geological Survey*

VSA – Verão Subártico

VML – Verão de Média Latitude

WRS – *Worldwide Reference System*

Medidas

μm - Micrômetro

cm – Centímetro

cm^2 – Centímetro quadrado

D – Diâmetro

m – Metro

m^2 – Metro quadrado

mm – Milímetros

km – Quilômetro

km^2 – Quilômetro quadrado

nm – Nanômetro

Bit – *Basic unit Information*

GB – Gigabyte

MB – Megabyte

$^{\circ}\text{C}$ – Grau Celsius

$^{\circ}\text{F}$ – Fahrenheit

K – Kelvin

g/m^3 - Grama por metro cúbico. Medida de densidade

hPa – Hectopascal. Medida de pressão

J – Joule

str – Esterradiano ou esferradiano

μW – Microwatts

W – Watts

W/m^2 - Watts por metro quadrado. Medida do fluxo radiante solar incidente na superfície do terreno por área de superfície

$\text{W}/\text{m}^2\mu\text{m}$ – Watts por metro quadrado por micrômetro. Medida da irradiância solar espectral no topo da atmosfera, multiplicada pela transmitância atmosférica num certo ângulo zenital solar, mais contribuição solar difusa

$\text{W}/\text{m}^2\text{str}\mu\text{m}$ - Watts por metro quadrado por esterradiano por micrômetro. Medida da radiância

$\mu\text{W cm}^{-2} \text{sr}^{-1} \text{nm}^{-1}$ - Microwatts por centímetros quadrados por esterradiano por nanômetro. Medida da radiância de entrada para o algoritmo FLAASH

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Contextualização	27
1.2	Objetivos	30
1.2.1	Objetivo Geral	30
1.2.2	Objetivos Específicos	30
2	REVISÃO BIBLIOGRÁFICA	31
2.1	MapBiomas	31
2.1.1	Google Earth Engine (GEE)	33
2.1.2	Google Drive	35
2.1.3	MapBiomas Workspace	36
2.2	Caatinga	37
2.3	Sensoriamento Remoto	41
2.4	Princípios da Radiação Eletromagnética	44
2.4.1	Conceitos de Radiância e Reflectância	45
2.5	Formatos das Imagens Digitais	47
2.6	Sistema LANDSAT	48
2.7	Sensoriamento Remoto da Vegetação	50
2.7.1	NDFI – Índice Normalizado por Diferença de Fração	52
2.8	Efeitos Atmosféricos	53
2.8.1	Espalhamento Atmosférico	54
2.8.2	Absorção Atmosférica	56
2.9	Correção Atmosférica	58
2.9.1	QUAC	60
2.9.2	Algoritmo FLAASH	62
2.10	Processamento Digital de Imagens (PDI)	65
2.10.1	Modelo Espectral de Mistura	66
2.10.2	Classificação Digital de Imagens	68
2.11	Avaliação da Qualidade dos Dados	70
2.11.1	Matriz de Confusão	70
2.11.2	Padrão, unidade e número de amostras	71
2.11.3	Coefficientes de concordância	73
2.12	Estado da Arte	78
3	MATERIAL E MÉTODOS	81
3.1	Procedimentos Metodológicos	81

3.2	Caracterização Climático-Temporal da Área de Mapeamento	86
3.3	Seleção das Cartas	87
3.3.1	CARTA SC-24-V-C	89
3.3.2	CARTA SD-23-X-D	92
3.4	Geração do Mosaico Temporal	93
3.5	Etapa de Processamento no ENVI (Correção Atmosférica)	96
3.5.1	Conversão dos dados brutos para Radiância e Reflectância TOA	96
3.5.2	Conversão para Radiância TOA	96
3.6	Aplicação do FLAASH	99
3.6.1	Configuração dos parâmetros de entrada e saída	99
3.6.2	Parâmetros da Cena e Informações do Sensor	101
3.6.3	Seleção dos Parâmetros Atmosféricos	103
3.6.4	Configurações de imagens Multiespectrais “Multispectral Settings”	107
3.6.5	Configurações Avançadas	108
3.7	Processamento do QUAC	110
3.8	Modelagem Espectral de Mistura (MEM)	110
3.9	Classificação da Cobertura do Solo	112
3.9.1	Caracterização das Classes	112
3.9.2	Árvore de Decisão	113
3.10	Pós-Classificação	117
3.10.1	Validação da Classificação	117
4	RESULTADOS E DISCUSSÃO	123
4.1	Classificação da Cobertura do Solo para a Carta SC-24-V-C	124
4.2	Classificação da Cobertura do Solo para a Carta SD-23-X-D	132
4.3	Comparação entre os resultados obtidos a partir dos coeficientes de concordância globais e por classe	140
4.4	Avaliação da Classificação da Cobertura do Solo nos dados com e sem correção atmosférica sob uma perspectiva temporal (2013-2016)	147
5	CONCLUSÕES E SUGESTÕES	157

1 INTRODUÇÃO

1.1 Contextualização

A Caatinga é a única grande região natural brasileira cujos limites estão inteiramente restritos ao território nacional. O bioma é proporcionalmente o menos estudado dentre as regiões naturais brasileiras, tendo grande parte do esforço científico voltado para determinados pontos em torno das principais cidades presentes no seu contexto territorial. Além disso, a Caatinga é a região natural brasileira menos protegida, pois possui menos de 2% de seu território coberto por unidades de conservação, sem considerar o extenso processo de degradação ambiental provocado pelo uso insustentável dos seus recursos naturais (LEAL et al., 2003).

A soma de todos esses fatores tem provocado a eliminação de processos ecológicos chaves, a perda de espécies únicas e a formação de extensos núcleos de desertificação em vários setores da região (LEAL et al., 2003). Isso faz com os esforços para a compreensão da dinâmica de uso e ocupação do solo devam ser intensificados no bioma, a fim de identificar o padrão de distribuição espacial de cada classe de cobertura do solo e as possíveis causas associadas à sua maior ou menor predominância no bioma ao longo do tempo. Daí vem a importância da classificação automatizada, que além de ser uma técnica que traz benefícios à conservação ambiental, permite categorizar os *pixels* da imagem analisada em diferentes classes pré-definidas de cobertura do solo.

Para melhor avaliar a classificação da cobertura do solo, torna-se necessário compreender a diferença entre o uso e a cobertura do solo, tendo em vista o fato de cada um remeter a uma diferente escala de abrangência na área a ser mapeada. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), o uso do solo é uma extensão do território apropriada e usada, e sua intensidade é determinada pelo contexto econômico, social e político da região avaliada. A cobertura do solo, por sua vez, envolve os elementos da natureza tais como vegetação, seja ela nativa ou não, água, rocha e demais construções artificiais que recobrem a superfície (IBGE, 2006). A classificação da cobertura do solo é considerada como pré-requisito para

aplicações em sensoriamento remoto, tais como mapeamento temático, monitoramento ambiental, dentre outras (LV et al., 2013).

O sensoriamento remoto é definido como a aquisição da informação de um determinado objeto sem que haja qualquer contato físico com o mesmo (ELACHI e VAN ZYL, 2006). Ainda de acordo com os autores, este termo é utilizado na maior parte das vezes em referência às técnicas eletromagnéticas de aquisição da informação, abrangendo todo o espectro eletromagnético. Essa atividade está fundamentada essencialmente na identificação e na discriminação de alvos, sendo a radiação recebida pelo sensor usada como base para realizar inferências quanto às características desses alvos (LATORRE et al., 2002). No entanto, existem limitações na correlação das informações sensor-superfície, uma vez que entre eles existe um meio extremamente dinâmico, a atmosfera, a qual interage com a radiação eletromagnética, provocando grandes alterações no fluxo radiante proveniente do alvo (LATORRE et al., 2002).

A interferência dos efeitos atmosféricos pode impactar a imagem no sentido de tornar alguns de seus dados mascarados. Consequentemente, devido a esse fato, e buscando um aumento na precisão dos dados de sensoriamento remoto, torna-se necessário tomar medidas para corrigir esses efeitos (RICHARDS e JIA, 2006). Dentre essas medidas destacam-se a conversão dos dados de radiância para reflectância. Porém, devido à mistura do sinal da atmosfera com o sinal da superfície, o que é obtido é denominado reflectância aparente, planetária ou no topo da atmosfera. Por outro lado, quando técnicas apropriadas são utilizadas com o objetivo de minimizar a contaminação promovida pela atmosfera no sinal captado, é obtida a reflectância de superfície (ANTUNES et al., 2003).

Atualmente, existem vários modelos que são usados na correção atmosférica de imagens multiespectrais. A correção atmosférica pode alterar os valores de reflectância em algumas bandas de diferentes formas (FONSECA, 2005), pois os efeitos de absorção e espalhamento atuam em menor ou maior escala, e este fato depende do comprimento de onda ou das bandas em que o sensor registra a imagem. Para a reflectância na superfície, a precisão do método de transferência radiativa e o modelo atmosférico têm uma influência significativa (ROJAS, 2005).

A base de dados da série Landsat contém o maior registro contínuo da superfície da Terra, visto do espaço, com a missão Landsat 8 estendendo esse registro há mais de 42 anos. Devido à sua cobertura temporal, à sua resolução

espacial a uma escala apropriada para monitorar a atividade humana, bem como o benefício do livre acesso ao público, o registro de dados do Landsat contribui consideravelmente para pesquisas voltadas à mudança da cobertura do solo. Um fator diferencial nestes estudos é a calibração radiométrica consistente dos sensores do Landsat. Esse elemento tem sido um fator chave contribuinte para o sucesso global da missão Landsat. Neste contexto, a caracterização contínua dos dados OLI é fundamental para manter a continuidade da alta qualidade dos dados.

O monitoramento dos recursos naturais pode ser otimizado por meio do uso do sensoriamento remoto e das técnicas de processamento digital de imagens, com o intuito de quantificar as alterações ocasionadas por fatores naturais e antrópicos. Um elemento fundamental na detecção de mudanças da cobertura vegetal, a partir de imagens orbitais, consiste em distingui-las de modificações inerentes à cena imageada, derivadas de mudanças ambientais e atmosféricas. Essas apresentam as respostas espectrais a partir das características dos objetos/alvos presentes no período em que a cena foi imageada, revelando as assinaturas espectrais dos mesmos. A partir disso é possível proceder com a classificação da imagem para a finalidade desejada.

Um dos projetos atuais no âmbito da classificação da cobertura do solo a nível nacional é o projeto intitulado Mapeamento Anual da Cobertura e Uso do Solo no Brasil – MapBiomias. Esse projeto vem sendo desenvolvido em escala nacional para os biomas brasileiros e têm passado por constantes adaptações à fim de tentar obter o melhor produto. As diversas classes abordadas no âmbito do projeto estão sendo identificadas e mapeadas com base em imagens das séries Landsat 5, 7 e 8 (sensores TM, ETM+ e OLI, respectivamente), sendo que atualmente, para o Landsat 5 e 7 são utilizadas coleções de imagens em reflectância de superfície ortorretificadas (L1T), enquanto que para o Landsat-8 os dados utilizados são de reflectância no topo da atmosfera. Isso ocorre porque os produtos disponibilizados pela plataforma do *Google Earth Engine*, os quais estão vinculados à biblioteca do USGS, não possuem dados em reflectância de superfície ortorretificados para o Landsat-8. No entanto, os dados em reflectância de superfície podem ser obtidos a partir do dado bruto e dos algoritmos presentes em alguns *softwares* de processamento de imagens, como o ENVI, por exemplo, dentre os quais se destacam o FLAASH e o QUAC.

Acredita-se que dados sem a necessidade de correção atmosférica (reflectância no topo da atmosfera) possam ser utilizados pelo MapBiomias e ainda assim garanta a qualidade das classificações automáticas obtidas. Com isso, a partir da seleção prévia de duas diferentes áreas da Caatinga, foi feito um comparativo entre o dado com a atmosfera corrigida obtido por meio dos algoritmos FLAASH e QUAC, e o produto em reflectância no topo da atmosfera (LC8_L1T_TOA) atualmente utilizado pelo MapBiomias no mapeamento da cobertura do solo da Caatinga no âmbito do Landsat-8. A partir de análises visuais e da aplicação de testes estatísticos foi identificado o dado que melhor se adequa para proceder com o mapeamento da cobertura do solo no bioma.

1.2 Objetivos

1.2.1 Objetivo Geral

Avaliar o dado de reflectância que melhor se ajusta à classificação da cobertura do solo da Caatinga no âmbito do projeto MapBiomias por meio da comparação entre dados Landsat-8 sem correção atmosférica (reflectância no topo da atmosfera) e dados submetidos à correção atmosférica por meio dos métodos FLAASH e QUAC (reflectância de superfície).

1.2.2 Objetivos Específicos

- Obter os parâmetros que melhor se ajustam para executar o FLAASH, observando o contexto da Caatinga;
- Testar a eficiência da árvore de decisão parametrizada pelo MapBiomias para a realidade da Caatinga por meio das classificações obtidas por meio do *Code Editor do Google Earth Engine*;
- Validar as classificações obtidas e comparar os resultados.

2 REVISÃO BIBLIOGRÁFICA

2.1 MapBiomias

O Observatório do Clima (OC) é uma rede que reúne entidades da sociedade civil com o objetivo de discutir a questão das mudanças climáticas no contexto brasileiro, promover encontros com especialistas na área, além de articular os atores sociais para que o governo brasileiro assuma compromissos e crie políticas públicas efetivas em favor da mitigação e da adaptação do Brasil em relação à mudança do clima (OBSERVATÓRIO DO CLIMA, 2015).

O Sistema de Estimativas de Emissões de Gases de Efeito Estufa (SEEG) é uma iniciativa do Observatório do Clima que compreende a produção de estimativas anuais das emissões de gases de efeito estufa no Brasil, documentos analíticos sobre a evolução das emissões e um portal na internet para disponibilização de forma simples e clara dos métodos e dados gerados no sistema. As Estimativas de Emissões de Gases do Efeito Estufa são geradas segundo as diretrizes do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), com base nos dados dos Inventários Brasileiros de Emissões e Remoções Antrópicas de Gases do Efeito Estufa, elaborado pelo Ministério da Ciência, Tecnologia e Inovação (MCTI), e em dados obtidos junto a relatórios governamentais, institutos, centros de pesquisa, entidades setoriais e organizações não governamentais (OBSERVATÓRIO DO CLIMA, 2013).

Em março de 2015, o SEEG/OC realizou um seminário na cidade de São Paulo e convidou especialistas em sensoriamento remoto e mapeamento de vegetação para se reunirem e verificarem a possibilidade de se produzir mapas anuais de cobertura e uso do solo para todo o Brasil de forma significativamente mais barata, rápida e atualizada, comparativamente aos métodos e práticas atuais, e que possibilitem recuperar o histórico das últimas décadas. Tal iniciativa deu origem ao Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MapBiomias).

Na reunião que deu origem ao MapBiomias, os especialistas identificaram que o projeto poderia ser desenvolvido desde que houvesse uma capacidade de processamento sem precedentes e um alto grau de automatização do processo,

além da participação de uma comunidade de especialistas em cada bioma e temas transversais. Assim, a partir deste diagnóstico foi estabelecido um contato com o Google que gerou um termo de cooperação técnica para desenvolver a iniciativa tendo como base a plataforma *Google Earth Engine* (GEE). Especificamente, o projeto teve início em julho de 2015 com um treinamento da equipe do MapBiomias sobre o *Google Earth Engine* na cidade de *Mountain View*, na Califórnia.

O propósito principal do projeto é contribuir para o entendimento da dinâmica do uso do solo no Brasil e em outros países tropicais tendo como base o desenvolvimento e implementação de uma metodologia rápida, confiável e de baixo custo para gerar mapas anuais de cobertura e uso do solo do Brasil a partir de 1985 até os dias atuais (e posterior atualização anual); criação de uma plataforma para facilitar a disseminação da metodologia para outros países e regiões interessadas utilizando a mesma base de algoritmos; e estabelecer uma rede colaborativa de especialistas nos biomas brasileiros para o mapeamento da cobertura do solo e da sua dinâmica de mudanças (MAPBIOMAS, 2016).

As principais características da iniciativa MapBiomias são: trabalho em rede com instituições responsáveis por diferentes biomas e temas transversais para otimizar as soluções; processamento distribuído e automatizado dos dados por meio da parceria com *Google Earth Engine*; trabalho orientado para gerar uma plataforma aberta, multiplicável e com possibilidade de aplicação em outros países e contextos; e a manutenção de uma plataforma colaborativa, desenhada para incorporar e acolher as contribuições da comunidade científica e demais interessados em colaborar (MAPBIOMAS, 2016).

Dentre os principais produtos gerados pelo MapBiomias, destacam-se aqueles voltados para o público em geral e para especialistas ou interessados em se aprofundar (MAPBIOMAS, 2016):

- Mosaicos de imagens de satélite com a melhor representação possível (p.ex., menos nuvens e ruídos) para cada ano da série histórica com resolução espacial máxima de 30m formado pela composição dos melhores *pixels* de cada conjunto de imagens de um local num determinado período de tempo. Os períodos do ano em que são selecionadas as imagens variam conforme a região (p.ex. período úmido na caatinga). Cada mosaico contém 14 camadas de informação incluindo as bandas espectrais e as frações (solo, vegetação, etc.).

- Mapas de cobertura e uso do solo, que se caracterizam por serem mapas no formato matricial (*pixel* de 30x30m). A legenda destes mapas evoluirá ao longo dos três primeiros anos de projeto assim como o período coberto, chegando ao ano de 2017 com mapas anuais desde 1985 com legenda compatível com a utilizada no inventário de emissões de gases de efeito estufa no Brasil.
- Relatório anual de transições de cobertura e uso do solo.
- Plataforma Web de consulta pública (*mapserver*) com imagens, mapas e a possibilidade de se gerar estatísticas sobre cobertura/uso do solo e suas transições.
- Plataforma Web de trabalho (*MapBiomias Workspace*): é o ambiente onde o trabalho de produção do MapBiomias ocorre. Nela é possível ajustar, para cada região específica, os diversos parâmetros de processamento e classificação das imagens bem como aplicar filtros espacial e temporal, além de realizar análises de concordância e gerar estatísticas dos mapas. Esta plataforma poderá ser multiplicada para aplicações em outros contextos.
- Coleção de *scripts* de processamento e classificação das imagens: permite a multiplicação e adaptação para outros contextos.

A metodologia de trabalho do MapBiomias é desenvolvida ao mesmo tempo em que são gerados protótipos rápidos para testar as hipóteses de caminhos para o processamento e classificação das imagens. As instituições estão baseadas em nove estados e operam de forma independente, mas conectadas. Os *scripts* e todo material de trabalho são compartilhados numa plataforma comum em três ambientes: *Code Editor* do *Google Earth Engine*, *Google Drive* e *MapBiomias Workspace*.

2.1.1 *Google Earth Engine (GEE)*

O *Google Earth Engine* trata-se de uma plataforma utilizada em ampla escala com o objetivo principal de fazer análise de dados ambientais. Uma das grandes vantagens dessa plataforma é o fato de ela reunir mais de 40 anos de imagens globais de satélites, sejam elas de décadas anteriores ou atuais. Essa plataforma também fornece ferramentas e uma vasta capacidade computacional para o

desenvolvimento de análises e exploração de uma elevada amplitude de dados. De acordo com o site da plataforma, a detecção de desmatamento, a classificação da cobertura da terra e suas alterações correspondentes, as estimativas de biomassa florestal e de carbono assim como o mapeamento de áreas sem estradas no mundo destacam-se como uma das principais aplicações atuais (GOOGLE EARTH ENGINE, 2017).

A ferramenta integra um conjunto de dados geoespaciais com cobertura global, a capacidade de armazenamento e processamento altamente elevados correspondentes ao ambiente de computação da nuvem Google, e um ambiente de desenvolvimento integrado suportando a implementação de algoritmos de análise e processamento de dados geoespaciais nas linguagens *Java Script* e *Python* (GORELICK, 2013).

Dentre os dados geoespaciais disponíveis no catálogo do Google podemos destacar vários produtos com cobertura regional e/ou global dos sensores ASTER, MODIS, LANDSAT, NOAA e produtos MeaSURES (novos registros de imagens da superfície terrestre que parte do princípio da junção de diferentes dados com o objetivo de formar uma série temporal única, consistente e coerente). Além dos dados já disponíveis na infraestrutura Google, o usuário pode enviar os seus dados para a integração/processamento remoto. O GEE pode ser classificado como uma PaaS (*Platform as a Service*), que fornece para especialistas, um ambiente de programação e um conjunto de dados para implementação de aplicações geoespaciais, principalmente para dados *raster*. Um PaaS trata-se de um ambiente baseado na nuvem no qual é possível desenvolver, testar, executar e gerenciar diferentes aplicativos, sem necessidade de construir ou gerenciar a infraestrutura subjacente. A Figura 1 apresenta uma descrição dos itens presentes no *Code Editor* do GEE, a plataforma utilizada pelo MapBiomass para o desenvolvimento dos *scripts* englobando todas as etapas de processamento abrangidas pelo projeto.

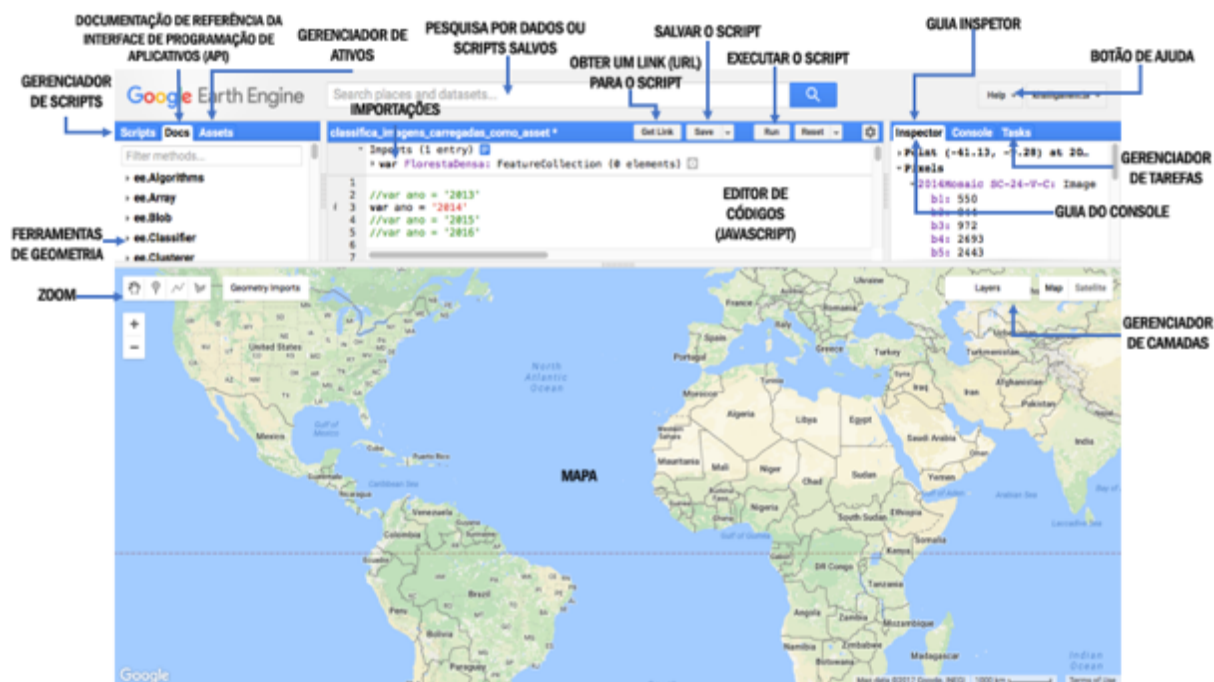


Figura 1 - Plataforma Code Editor do Google Earth Engine (code.earthengine.google.com) e suas principais finalidades.

2.1.2 Google Drive

O Google Drive® além de gratuito é muito útil, pois tem um pacote que se assemelha ao Microsoft® Office, além de poder importar e exportar arquivos, aplicativos, mídias e fotos, independentemente de suas extensões ou ainda sistemas operacionais diferentes (GOOGLE, 2014). Uma outra vantagem do Google Drive® é a sua portabilidade, já que se trata de um serviço em nuvem, o qual não requer um espaço físico para armazenar os dados, sendo necessário apenas acessar a Internet para obtê-los. Isso faz com que inúmeras pessoas trabalhem simultaneamente em um mesmo arquivo sem a necessidade de enviar ou manter um controle de mudanças (GOOGLE, 2014).

O Google Drive® se destaca pela sua popularidade, usabilidade, portabilidade, convergência e escalabilidade (GOOGLE, 2014). Dessa forma, caso o espaço gratuito de 15 GB seja considerado insuficiente, o usuário pode adquirir um espaço maior, bastando pagar por esse serviço.

2.1.3 MapBiomas Workspace

O MapBiomas *Workspace* é o ambiente de trabalho da plataforma (workspace.mapbiomas.org), a qual é utilizada como base para processamento e aquisição das imagens disponíveis no acervo do GEE. Um dos benefícios dessa plataforma é a falta de necessidade de entrar em linhas de código de programação, uma vez que um aplicativo que organiza o fluxo de trabalho foi criado pelos programadores e desenvolvedores envolvidos na iniciativa, permitindo que cada os membros envolvidos na equipe consigam operar paralelamente, na mesma plataforma, cada um possuindo controle total sob todas as variáveis importantes para gerar o melhor produto (MAPBIOMAS, 2016).

É importante destacar que o desenvolvimento dessa plataforma é resultado de um esforço colaborativo de associações não governamentais, universidades e institutos de pesquisa, sendo elas: IMAZON, Universidade Estadual de Feira de Santana – UEFS, Associação de Plantas do Nordeste – APNE, Instituto de Pesquisa Ambiental da Amazônia – IPAM, Fundação SOS Mata Atlântica e Pantanal, ArcPlan Geoprocessamento, Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás – LAPIG/UFG, Agrosatélite, Ecostage, Terras App, IDS, Fundação AVINA, Instituto Tecnológico Vale e Google.

A Figura 2 apresenta o design da plataforma, cujo ambiente de trabalho é utilizado pelo projeto MapBiomas para proceder com o processamento e classificação das imagens mapeadas do bioma Caatinga.

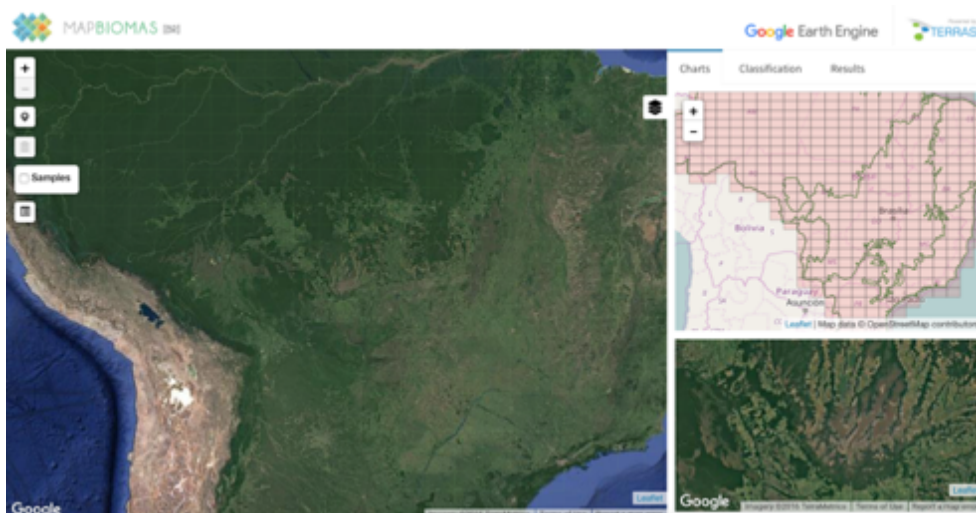


Figura 2 - Design do projeto MapBiomas na internet (workspace.mapbiomas.org)

2.2 Caatinga

A Caatinga é o único bioma exclusivamente brasileiro, o que quer dizer que grande parte do seu patrimônio biológico não pode ser encontrado em nenhum outro lugar do mundo. Seu nome originou-se do Tupi-Guarani e significa “floresta branca”, que caracteriza bem a paisagem esbranquiçada apresentada pela vegetação durante o período seco, onde grande parte das plantas perde as folhas e os troncos tornam-se esbranquiçados e secos (ALBUQUERQUE E BANDEIRA, 1995). No entanto, é importante salientar que há duas definições diferentes para a palavra caatinga: a “Caatinga” e a “caatinga”. Enquanto a primeira, iniciada com a letra maiúscula, se refere ao bioma, que é a região semiárida, a segunda, escrita com letra minúscula, é um tipo de vegetação, que é primariamente florestal, apesar de também possuir formações mais abertas, campestres, e que é bastante adaptada aos acentuados períodos de estiagem ocorrentes no semiárido brasileiro (MACHADO, 2013)

O bioma estende-se entre os paralelos 2° e 17° sul, meridianos 35° e 45° oeste e ocupa uma área de cerca de 850 mil km², o que equivale a 9,92% do território nacional (IBGE, 2004). Conforme mostra a Figura 3, a Caatinga inclui os estados do Ceará (100%), a maior parte do Rio Grande do Norte (95%), Paraíba (94%) e Pernambuco (83%), sudeste do Piauí (63%), região norte e central da Bahia (54%), oeste de Sergipe (49%) e Alagoas (48%), e uma faixa estendendo-se em Minas Gerais (2%) seguindo o rio São Francisco, juntamente com um enclave no vale seco da região média do rio Jequitinhonha. Além disso, o bioma possui uma abrangência territorial bastante reduzida no estado do Maranhão (1%).

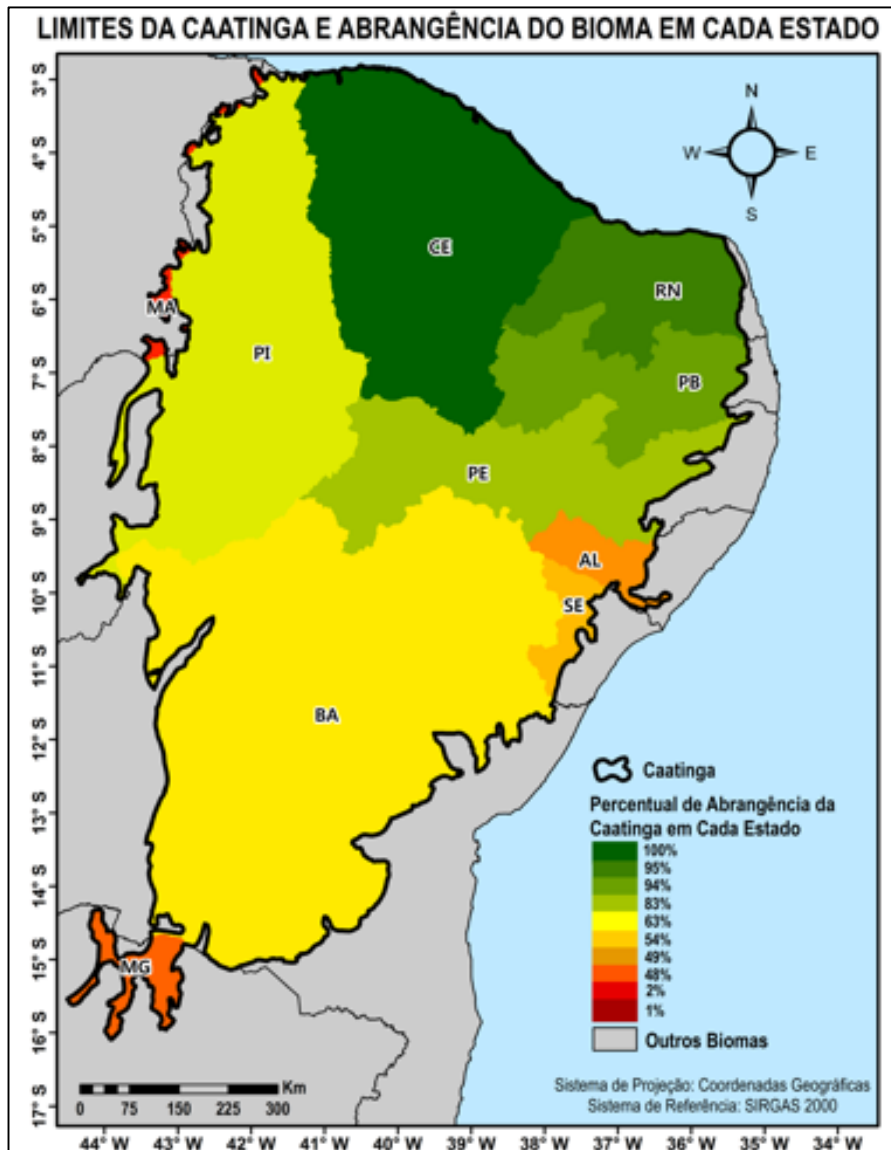


Figura 3 - Mapa do bioma Caatinga, indicando os estados sob seu domínio e o grau de abrangência do bioma em relação à área total de cada estado

Na maior parte de sua extensão, a Caatinga é caracterizada por apresentar um clima quente e semiárido, marcado por uma longa estação seca (EITEN, 1982) e irregularidade pluviométrica (ANDRADE-LIMA, 1981), com precipitação anual variando entre 400 e 600 mm (AB'SABER, 1977), distribuídos quase sempre por um período de três a seis meses (VELLOSO et al., 2002). A pluviosidade total varia muito a cada ano e, em intervalos de dez a vinte anos, chegam a atingir menos da metade da média, muitas vezes durante períodos de três a cinco anos seguidos, caracterizando, assim, o fenômeno conhecido como “seca” (VELLOSO et al., 2002). Há uma maior incidência de secas ao norte do rio São Francisco do que ao sul, onde as chuvas são mais bem distribuídas ao longo da estação chuvosa.

As regiões hidrográficas inseridas sob o domínio da Caatinga são: Parnaíba, São Francisco, Atlântico Nordeste Oriental e Atlântico Leste, tendo cada uma, bacias com diferentes características hidrográficas e graus de abrangência dentro da área do bioma. Além disso, o caráter intermitente e sazonal da maioria dos rios da Caatinga sofre influência da aridez da região (ROSA et al., 2003).

A região hidrográfica do Parnaíba é formada pelas bacias do Maranhão e Piauí, que estão situadas na porção norte-ocidental da Caatinga, e representam a zona de transição entre o clima semiárido da Caatinga à leste do Rio Parnaíba e o clima mais úmido do Cerrado ao oeste. A região hidrográfica Atlântico Nordeste Oriental inclui as bacias que estão compreendidas entre o rio Parnaíba e o rio São Francisco, as quais sofrem maior influência do clima semiárido do bioma, se comparada às outras regiões (ROSA et al., 2003). A região hidrográfica do São Francisco, por sua vez, é a terceira maior do Brasil (AB'SÁBER, 1956). O rio São Francisco, apesar de ter suas cabeceiras localizadas na serra da Canastra em Minas Gerais, é nordestino na maior parte de seu curso, onde se mantém perene mesmo na região da Caatinga (ROSA et al., 2003). Por fim, a região hidrográfica do Atlântico Leste sob influência da Caatinga compreende as bacias costeiras abaixo da foz do São Francisco (entre os estados de Alagoas e Sergipe) até o rio de Contas, na Bahia.

As principais unidades de relevo do bioma são o planalto da Borborema (parte oriental), as grandes depressões (entorno dos grandes rios), as chapadas e chapadões (porção meridional) e o espinhaço (de Juazeiro- BA até Minas Gerais). O planalto da Borborema é considerado por Rosa et al. (2003) o grande gestor de águas da sub-região oriental da Caatinga, direcionando os rios no sentido oeste-leste até o Oceano Atlântico.

Além disso, os solos predominantes são os Latossolos e Argissolos e costumam variar de extremamente rasos e pedregosos (imagem típica do sertão seco coberto de cactáceas) a moderadamente profundos, dando lugar às caatingas de areia e a grandes vazios demográficos, como o Raso da Catarina. Os solos da Caatinga também podem ser de fertilidade baixa (como o da chapada sedimentar de Ibiapaba) ou alta (como a chapada cárstica do Apodi). A prática intensiva do agronegócio, associada a desmatamentos, assim como a onipresença de caprinos, são os principais fatores responsáveis pela degradação dos solos do bioma, além de impulsionarem processos de desertificação em algumas áreas.

As temperaturas do bioma são relativamente estáveis com média anual na faixa de 24 a 26°C, podendo ser atenuadas nas áreas mais elevadas para uma média ao redor de 22°C (JACOMINE, 1996; SILVA et al., 1993). Nesse ambiente a evaporação média anual situa-se ao redor de 2000 mm (SÁ E SILVA, 2010), o que implica em uma vegetação com maior vulnerabilidade à deficiência hídrica sazonal, agravada especialmente nos anos de seca. O bioma apresenta um regime climático enquadrado no tipo Bsh, segundo a classificação de Köppen, semelhante a outras áreas tropicais semiáridas do globo (NIMER, 1989).

A Caatinga apresenta um mosaico com tipos de vegetação bastante variados, caracterizados, em geral, por formações vegetais xerófilas, lenhosas, decíduas, com muitas espécies espinhosas, compreendendo um estrato arbóreo esparsos (8 a 12 metros), outro arbóreo-arbustivo e/ou arbustivo (2 a 5 metros), e um herbáceo estacional (abaixo de 2 metros), conforme o período das chuvas. Contraditoriamente, a flora dos sertões é constituída por espécies com longa história de adaptação ao calor e à seca (MARTINS, 2007). Prova disso é a presença de espécies caducifólias, que em geral perdem as folhas na estação seca, além de muitas cactáceas. Dentre as espécies vegetais mais comuns da caatinga, estão a jurema, o umbuzeiro, o marmeleiro, o mandacaru, o xique-xique, a faveleira e o pinhão-bravo.

A vegetação da Caatinga, a qual é considerada majoritariamente como savana estépica em termos de extensão territorial, se divide em quatro tipos (IBGE, 1992):

a) florestada: composta por espécies medindo, em torno, 5 a 7 metros de altura; mais ou menos densas, com grossos troncos. Possuem espinhos e são decíduas na época desfavorável. Os gêneros dominantes são: *Cavanillesia*, *Chorisia*, *Acacia*, *Mimosa* e outros.

b) arborizada: apresenta as mesmas características do tipo Florestada, diferindo, apenas, na altura dos indivíduos (mais baixos) e em seu espaçamento, com maior abertura entre os indivíduos. Predominam as seguintes espécies e gêneros: *Spondias tuberosa*, *Commiphora leptophloeos* e *Mimosa*.

c) parque: composta, principalmente, pelas espécies *Mimosa acustipula*, *Auxema oncolalyx* e *Aspidosperma pyriformium*, esta área recebe este nome por recobrir pequenas depressões que, à época das chuvas, são alagadas e, também, por ter seus indivíduos distribuídos sobre denso tapete gramíneo-lenhoso.

d) gramíneo-lenhosa: Caracteriza-se por um extenso tapete graminoso, salpicado de plantas lenhosas anãs espinhosas. Os campos são cobertos inteiramente pelo capim panasco (*Aristida sp.*), que enverdece na época das chuvas.

De acordo com Velloso et al. (2002), a vegetação considerada mais típica encontra-se nas depressões sertanejas, ao norte e ao sul do bioma, separadas por uma série de serras que constituem uma barreira geográfica para diversas espécies. Entretanto, ainda assim, as regiões mais altas e de relevo variado também se destacam por apresentarem os diversos tipos de caatinga

Muitos estudos apontam o número considerável de fitofisionomias que a Caatinga possui (EGLER, 1951; HUECK, 1972; ANDRADE-LIMA, 1981; RIZZINI, 1997; RODAL e SAMPAIO, 2002; PRADO, 2003). Nesse contexto, a fim de conservar e compreender melhor o bioma, Velloso et al. (2002) dividiram a Caatinga em oito ecorregiões naturais, as quais foram definidas com base nos tipos de solo, clima, temperatura, conforto, altitude, pluviosidade e grupos taxonômicos de fauna e flora tipicamente observados nas regiões abrangidas pelo bioma. Tratam-se das seguintes ecorregiões: Complexo Chapada Diamantina, Complexo Campo Maior, Complexo Ibiapaba-Araripe, Depressão Sertaneja Meridional, Depressão Sertaneja Setentrional, Terras Altas do Borborema e Raso da Catarina.

2.3 Sensoriamento Remoto

A coleta de dados por sensoriamento remoto foi feita de diversas formas, dentre as quais se destacam as câmeras montadas em aeronaves suborbitais. A *fotogrametria* foi definida nas primeiras edições do *Manual of Photogrammetry* como “a arte ou ciência de obter medidas confiáveis por meio da fotografia” (AMERICAN SOCIETY OF PHOTOGRAMMETRY, 1952). Já Colwell (1960) definiu a interpretação fotográfica como sendo o ato de examinar imagens fotográficas com a finalidade de identificar objetos e julgar sua significância.

De acordo com Jensen (2009), a real cunhagem do termo sensoriamento remoto remonta a um artigo não-publicado do começo dos anos 1960 feito pelo grupo do *Office of Naval Research (ONR) Geography Branch*, o qual teve Evelyn L. Pruitt como autora e Walter H. Bailey como colaborador e membro do grupo. O artigo originou-se em função de as pesquisas do Grupo de Geografia do ONR

estarem sendo expandidas usando instrumentos além de câmeras, tais como scanners e radiômetros, passando a abranger regiões do espectro eletromagnético além do visível e do infravermelho próximo (infravermelho termal e micro-ondas, por exemplo). Assim, no fim dos anos 1950 ficou claro para os autores que o prefixo “foto”, que quer dizer, literalmente, “escrever com luz [visível]”, estava sendo usado muito além do seu real significado (COLWELL, 1997). A partir de então o termo sensoriamento remoto passou a ser promovido numa série de simpósios patrocinados pelo ONR nos Laboratórios *Willow Run* da Universidade de Michigan em conjunto com o *National Research Council* durante os anos 1960s e início dos 1970s, tendo sido usado desde então.

Sensoriamento remoto foi definido formalmente pela *American Society of Photogrammetry and Remote Sensing* (ASPRS) como “a medição ou aquisição de alguma propriedade de um objeto ou fenômeno, por um dispositivo de registro que não esteja em contato físico ou íntimo com o objeto ou fenômeno em estudo” (COLWELL, 1983). Já em 1988, a ASPRS adotou uma definição combinada de fotogrametria e sensoriamento remoto como sendo a arte, ciência e tecnologia de obter informação confiável sobre objetos físicos e o ambiente por meio do processo de registro, medição, e interpretação de imagens e representações digitais dos padrões de energia derivados de sistemas sensores sem contato físico (COLWELL, 1997).

A partir da sua consolidação, o termo sensoriamento remoto recebeu um grande número de definições (FISCHER, 1976). A Tabela 1 apresenta os principais conceitos atribuídos ao termo sensoriamento remoto ao longo do tempo, e seus respectivos autores.

Tabela 1 - Principais definições do termo sensoriamento remoto

Autor (es)	Definição do termo Sensoriamento Remoto
Barrett E Curtis (1992)	“Ciência de observação à distância”.
Colwell (1966)	“Reconhecimento a distância”.
Crepani (1983)	“É a ciência e a arte de se obterem informações sobre um objeto, área ou fenômeno, por meio da análise de dados coletados por aparelhos denominados sensores, que não entram em contato direto com os alvos em estudo”.
Curran (1995)	“Uso de sensores de radiação eletromagnética para registrar imagens do meio físico que possam ser interpretadas de modo a gerar informações úteis”.

Florenzano (2011)	“Tecnologia que permite obter imagens – e outros tipos de dados – da superfície terrestre, por meio da captação e do registro da energia refletida ou emitida pela superfície”.
Lintz E Simonetti (1976)	“Arte ou ciência de dizer algo sobre um objeto sem tocá-lo”.
Lillesand E Kieffer (1994)	“É a arte e a ciência de estudar a matéria sem ter contato físico com a mesma baseando-se somente da interação da radiação eletromagnética”.
Mather (1987)	“Medida à distância da assinatura espectral da superfície da Terra e da atmosfera”.
Novo (1989)	“Utilização conjunta de modernos sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves, espaçonaves, etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias do planeta Terra em suas mais diversas manifestações”.
Weng (2010)	“Sensoriamento remoto refere-se às atividades de registro, observação, percepção e compreensão dos objetos ou eventos em lugares distantes (remotos).”

De acordo com Florenzano (2011) o termo sensoriamento está associado à obtenção de dados por meio de sensores instalados em plataformas terrestres, aéreas (balões e aeronaves) e orbitais (satélites artificiais). O termo remoto, que significa distante, é utilizado porque a obtenção é feita à distância, ou seja, sem o contato físico entre o sensor e objetos na superfície terrestre. O processamento, a análise e interpretação desses dados também integram o sensoriamento remoto.

De acordo com Meneses (2012) a definição mais clássica do termo sensoriamento remoto é: “uma técnica de obtenção de imagens dos objetos da superfície terrestre sem que haja um contato físico de qualquer espécie entre o sensor e o objeto”. Já a definição mais científica que se pode dar ao termo, de acordo com o mesmo autor, seria: “ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas e interações da radiação eletromagnética com os materiais terrestres”. Baseado nisso surge a dúvida se o termo se trata de uma técnica ou uma ciência.

De acordo com Fussell et al. (1986), o uso de sensores remotos sofisticados para medir a quantidade de energia eletromagnética emitida por um objeto ou área geográfica à distância, seguida da extração de informação importante a partir dos dados obtidos usando algoritmos baseados em matemática e estatística já é por si

só uma atividade científica. Ao mesmo tempo o processo de interpretação visual de uma foto ou imagem exige não apenas conhecimento científico, mas todo o conhecimento que uma pessoa obteve durante toda a sua vida. Tal conhecimento não pode ser medido, programado, ou entendido completamente. A sinergia da combinação do conhecimento científico com a experiência de mundo real do analista permite ao intérprete desenvolver métodos heurísticos práticos para extrair importantes de uma imagem.

2.4 Princípios da Radiação Eletromagnética

A energia registrada por um sistema de sensoriamento remoto sofre certas interações fundamentais que precisam ser entendidas para que os dados de sensoriamento remoto possam ser interpretados apropriadamente. Por exemplo, no caso de um sensor passivo, em que a energia provém do Sol, tal energia, de acordo com Jensen (2009): 1) é radiada pelas partículas atômicas na fonte (Sol), 2) viaja no vácuo espacial à velocidade da luz, 3) interage com a atmosfera da Terra, 4) interage com a superfície da Terra, 5) interage com a atmosfera da Terra novamente, e 6) finalmente atinge o sensor, onde ela interage com vários componentes ópticos, filtros, emulsões de filmes, ou detectores.

É instrutivo examinar cada uma dessas interações fundamentais que a energia eletromagnética realiza à medida que progride da sua origem até o(s) detector(es) do sistema de sensoriamento remoto. O entendimento dessas interações ajuda o analista de imagens a extrair informações úteis dos dados de sensoriamento remoto (TUOMINEN E PEKKARINEN, 2004).

Meneses (2012) explica que a definição do que é radiação eletromagnética (REM) se inicia pela compreensão do caráter dual da sua natureza, isto é, ora atuando como uma forma de onda, ora de energia, o que de acordo com o autor, deve ser sempre levado em consideração ao explicar tudo aquilo que é observado nas imagens com relação às características dos objetos. Essa dualidade é explicada por dois modelos: ondulatório (onda) e corpuscular (energia).

Segundo o modelo ondulatório, a REM pode ser definida como uma oscilação dos campos elétrico e magnético, segundo um padrão harmônico de ondas, ou seja, ondas espaçadas por repetidas vezes no tempo (MENESES, 2012). O autor destaca

que esses campos dinâmicos ocorrem de forma indissociável. Além disso, de acordo com esse modelo as características das imagens são explicadas em função da relação entre o tamanho da onda e o tamanho do objeto

Já sob a ótica do modelo corpuscular, conforme explicita Meneses (2012), a REM é definida como uma forma dinâmica de energia que se manifesta somente por suas interações com a matéria. A porção da energia da REM que não é absorvida é refletida para o sensor. Nesse processo, as imagens medem a radiação refletida, mas, indiretamente, é possível avaliar o que foi absorvido pelos materiais. Isso é importante, porque são essas quantidades de energia eletromagnética absorvidas pelos materiais que definem algumas informações sobre a composição dos alvos terrestres, nas imagens de sensoriamento remoto. (MENESES, 2012).

Conforme resumido por Meneses (2012), para o sensoriamento remoto, o modelo ondulatório se aplica melhor para os grandes comprimentos de onda das micro-ondas das imagens de radar, que são obtidas com valores maiores que 3 cm. Por isso a imagem dos objetos é retratada por meio da interação da onda com a rugosidade de suas superfícies a um nível macroscópico. Já para comprimentos de onda menores, o modelo corpuscular é mais adequado, pois possuem maiores energias, o que explica o fato de a imagem dos objetos ser o reflexo da interação com suas combinações em um nível microscópico.

2.4.1 Conceitos de Radiância e Reflectância

Quando o sensor detecta e mede a radiação que deixa a superfície dos objetos, ele está fazendo uma medição radiométrica. É por isso que os sensores imageadores também podem ser denominados de radiômetros imageadores (MENESES, 2012). A radiometria inclui uma série de termos e leis que em sensoriamento remoto são fundamentais para explicar o significado físico da REM medidos pelo sensor. A Figura 4 apresenta um esquema no qual é possível observar os fatores que interferem no valor da radiância (L_0) efetivamente medido pelo sensor.




Figura 4 - Fatores que influenciam na radiância em um sensor orbital

Fonte: Ponzoni et al. (2012)

Ponzoni et al. (2012) explicam que o fluxo de radiação eletromagnética proveniente do Sol é denominado irradiância, E_0 . De toda a intensidade de REM emitida pelo Sol, parte é recebida diretamente pelo objeto, E_b , enquanto outra parte recebe uma porção difusa, E_d . O fluxo de radiação recebido pelo sensor, por sua vez, contém a radiância real ou de superfície, L_s , que representa a radiância específica do objeto; a intensidade de fluxo decorrente de sua trajetória, L_p ; uma porção da radiação que é espalhada pela atmosfera, m ; e a contribuição de objetos vizinhos àquele de efetivo interesse, a .

Meneses (2012) chama atenção para o fato de a irradiância variar no tempo, uma vez que tanto a distância como a posição do Sol mudam continuamente em relação à Terra. Além disso, ainda de acordo com o autor, a atmosfera deixa passar quantidades diferentes de fluxo radiante a cada momento devido às absorções dos gases, o que faz com que a radiância medida no sensor para construir a imagem dos objetos se mostre diferente de um dia para o outro, mesmo que os alvos nada tenham mudado. A relação de medida da irradiância com a radiância estabelece o conceito de reflectância, muito importante no sensoriamento remoto.

Reflectância é a razão entre a quantidade de energia radiante que deixa uma unidade de área no terreno (radiância) pela quantidade de energia incidente naquela área (Irradiância), medida no mesmo instante de tempo (MENESES, 2012). Como irradiância e radiância são densidades de fluxo, o valor dessa razão torna-se adimensional, sendo, portanto, expresso em porcentagem, qualquer alvo no terreno poderá refletir uma porcentagem $> 0\%$ e $< 100\%$ da radiação nele incidente. Usa-se a letra grega ρ para se referenciar à reflectância.

Conforme salientado por Ponzoni et al. (2012), uma vez convertidos para radiância aparente, assume-se que os dados contidos nas imagens de diferentes bandas de um mesmo sensor ou de sensores diferentes podem ser comparados entre si. Contudo, ainda de acordo com o autor, como a radiância é um parâmetro radiométrico dependente da intensidade de radiação radiada pela fonte, ela passa a não ser o parâmetro mais apropriado para avaliações das propriedades espectrais de objetos. Nesse caso, a reflectância passa a assumir papel de destaque nesses tipos de estudo, já que as propriedades espectrais de um objeto são expressas pelos fatores de reflectância.

Quando o fator de reflectância é calculado mediante valores de radiância aparente, essa é dita como sendo um fator de reflectância aparente (topo da atmosfera). Existem equações específicas para converter dados de números digitais para tanto para radiância como para reflectância. Estas são apresentadas e detalhadas no Capítulo 3.

2.5 Formatos das Imagens Digitais

Outro aspecto que precisa ser levado em consideração pelo analista é o formato de arquivo em que a imagem é armazenada. De acordo com Van Aardt et al. (2010), os formatos binários genéricos mais comuns são: sequencial por banda (BSQ), intercalado por *pixel* (BIP) e intercalado por linha (BIL). O formato BSQ armazena cada banda como um formato separado, o que permite com que cada banda seja analisada como uma entidade separada e individual. Dados de sensoriamento remoto geralmente são armazenados, o que permite com que cada banda espectral seja acessada separadamente. O formato BIP armazena todas as camadas de dados de um *pixel* como membros adjacentes do conjunto de dados. Já

o formato BIL está compreendido entre os formatos BSQ e BIP. Nele, as linhas de cada banda são armazenadas adjacentes uma à outra e, assim, características diferentes de uma linha que correspondem umas às outras estão localizadas próximas uma da outra no conjunto de dados. Os autores ainda destacam que os três formatos não comprimem os dados brutos nos seus formatos originais.

Formatos tais como BSQ, BIP e BIL são frequentemente encapsulados dentro de um formato de arquivo de imagem proprietário – TIFF (*tagged image file format*). Trata-se do formato mais comum para o armazenamento de fotografias e imagens digitais, cujo propósito é descrever e armazenar imagens *raster*. De acordo com Ramos (2000), o formato TIFF é capaz de armazenar tanto imagens em tons de cinza como multicores e tem a vantagem de ser reconhecido por qualquer tipo de programa de processamento de imagens, sendo baseado em entidades lógicas, cada uma consistindo de uma etiqueta com significado específico, que descreve atributos e parâmetros dos dados de uma imagem.

2.6 Sistema LANDSAT

Em 1967, a *National Aeronautics & Space Administration* (NASA), encorajada pelo Ministério do Interior americano, iniciou o programa *Earth Resource Technology Satellite* (ERTS). Esse programa resultou no lançamento de oito satélites com uma diversidade de sistemas de sensoriamento remoto construídos para adquirir informação dos recursos da Terra. Os sensores mais marcantes foram os de varredura multiespectral (*Landsat Multispectral Scanners*) e os mapeadores temáticos (*Landsat Thematic Mappers*). O programa Landsat é o sistema de satélite de observação da Terra mais antigo dos Estados Unidos, tendo adquirido dados desde 1972.

O satélite ERTS-1, lançado em 23 de julho de 1972, foi um sistema experimental construído para testar a possibilidade de adquirir dados de recursos da Terra por satélites não-tripulados. Antes do lançamento do ERTS-B em 22 de janeiro de 1975, a NASA rebatizou o programa ERTS de Landsat, distinguindo-o do satélite de micro-ondas ativas Seasat, lançado em 26 de junho de 1978. Nesta época o ERTS-1 foi retroativamente denominado Landsat-1 e o ERTS-B de Landsat-2 no lançamento. O Landsat-3 foi lançado em 5 de março de 1978; o Landsat-4 em 16 de

julho de 1982; o Landsat-5 em 1 de março de 1984; o Landsat-6 em 5 de outubro de 1993; o Landsat-7 em 15 de abril de 1999; e, por fim, o Landsat-8 em 11 de fevereiro de 2013.

O Landsat-8 foi lançado em 11 de fevereiro de 2013 e tem como objetivo principal coletar, arquivar, processar e distribuir dados científicos de forma consistente com o registro de dados existente dos demais sensores da série Landsat (IRONSON et al., 2012). Dentre os seus principais requisitos destacam-se: uma vida útil de cinco anos; uniformidade das larguras das bandas espectrais e dos comprimentos de onda centrais; desempenho radiométrico incluindo incerteza de calibração absoluta, relações sinal-ruído, sensibilidade à polarização e estabilidade; distâncias da amostra de solo e resposta da borda; geometria de imagem e geolocalização, incluindo o co-registo de bandas espectrais, sem falar na entrega de algoritmos de processamento de dados.

O satélite é referenciado ao sistema WRS-2 e opera em uma órbita polar sol síncrona próxima de 705 km de distância da superfície terrestre e cruzando a linha do Equador aproximadamente às 10:13 da manhã, horário médio local durante o nó descendente de cada órbita. O L-8 possui resolução radiométrica de 16 bits, resolução temporal de 16 dias e 185 km de faixa imageada e destaca-se pela presença de dois instrumentos imageadores: um óptico, *Operational Land Imager* – OLI, e outro abrangendo a faixa do infravermelho termal, *Thermal Infrared Sensor* – TIRS, o qual apresenta duas bandas espectrais de ondas longas (bandas 10 e 11) que equivalem ao comprimento de onda antes coberto por uma única banda do sensor TM, a banda 6 (USGS, 2012).

O Instituto Nacional de Pesquisas Espaciais – INPE é o órgão responsável pela distribuição gratuita das imagens Landsat no Brasil, com exceção dos dados do sensor TIRS, ainda não disponíveis em seu catálogo de imagens. O Serviço Geológico dos Estados Unidos (USGS) distribui tanto dados Landsat como de outros satélites. Os dados do TIRS do Landsat-8, apesar de serem coletados originalmente com resolução espacial de 100 metros, estão disponíveis reamostrados para 30 metros pelo USGS para fins de comparação com dados do OLI. A banda pancromática, por sua vez, possui resolução espacial de 15 metros.

2.7 Sensoriamento Remoto da Vegetação

A vegetação possui grande participação na redução de processos erosivos, pois intercepta gotas de chuva que podem impactar diretamente a superfície do solo. Além disso, a vegetação é considerada um importante indicador ambiental, influenciado fatores climáticos, edafológicos e bióticos, o que ao final contribui para a estabilização do meio ambiente. Cabe a compreensão da relação do sensoriamento remoto aplicado para a vegetação, uma vez que o MapBiomas utiliza índices de vegetação como parâmetros para a classificação da cobertura do solo. Para o caso da Caatinga, o NDFI, apresentado no subitem 2.7.1, é o índice que serve como subsídio para a classificação da vegetação no bioma.

A principal motivação dos estudos em vegetação envolvendo a aplicação de técnicas de sensoriamento remoto, fundamenta-se na compreensão da aparência que uma dada cobertura vegetal assume em um determinado produto de sensoriamento remoto. Para Ponzoni (2002) a avaliação da cobertura vegetal se dá essencialmente por meio da interação da energia eletromagnética com a planta, a qual por sua vez envolve muitos parâmetros e fatores ambientais, tais como a estrutura do dossel, o fluxo de radiação incidente, assim como as características físico-químicas dos elementos que constituem a vegetação. Entretanto, de acordo com Ponzoni (2002), de todos os elementos constituintes da vegetação, a folha pode ser considerada o principal.

Para uma melhor compreensão das características de reflectância da radiação eletromagnética incidente sobre uma folha é necessário que se conheça a sua composição química, em especial o tipo e quantidade de pigmentos fotossintetizantes, e sua morfologia interna. Além disso, de acordo com Ponzoni (2002), o comportamento da folha pode ser observado especialmente em três regiões específicas do espectro eletromagnético: visível (0,4 a 0,7 μm), infravermelho próximo (0,7 a 1,3 μm) e infravermelho de ondas curtas (1,3 a 2,6 μm). A Figura 5 apresenta a curva de reflectância característica da vegetação, destacando ainda sua variação em diferentes comprimentos de onda, sendo que a faixa dos raios ultravioletas não foi considerada, uma vez que grande parte da energia nesse intervalo é absorvida pela atmosfera e a vegetação não faz uso dela.




Figura 5 - - Comportamento espectral característico da vegetação nos comprimentos de onda do visível e infravermelho próximo e de ondas curtas. Fonte: Novo (1989)

De maneira resumida, na região do visível os pigmentos existentes nas folhas dominam a reflectância espectral. Na região do infravermelho próximo, a reflectância espectral é quase constante e existe uma absorção pequena da radiação eletromagnética, e considerável espalhamento interno na folha, com baixa absorção da água. Já na região do infravermelho de ondas curtas a absorção devido à água líquida predomina na reflectância espectral das folhas da região do infravermelho próximo.

À medida que se passa da escala da folha para a escala do dossel, a variação espectral diminui, possibilitando a análise da vegetação em escala regional. Partindo desse pressuposto, surgiram os índices de vegetação derivados de imagens de satélites, os quais por sua vez, além de realçar o comportamento espectral da vegetação possuem relação direta com o vigor da vegetação verde, porcentagem de cobertura do solo, atividade fotossintética e produtividade (HUETE et al., 1999).

Desde a década de 1960, os cientistas vêm extraído e modelando vários parâmetros biofísicos da vegetação com o uso de dados de sensoriamento remoto. Grande parte desse esforço tem envolvido o uso de índices de vegetação, que se tratam de medidas radiométricas adimensionais que indicam a abundância relativa e

a atividade da vegetação verde, incluindo índice de área foliar (IAF), porcentagem de cobertura verde, teor de clorofila, biomassa verde, e radiação fotossinteticamente ativa absorvida. Idealmente, um índice de vegetação ideal deve (RUNNING et al., 1994; HUETE et al., 1999):

- Maximizar a sensibilidade a parâmetros biofísicos das plantas, preferencialmente de uma forma linear, para que esta sensibilidade seja fidedigna para uma grande amplitude de condições da vegetação e para facilitar a validação e a calibração do índice;
- Normalizar ou modelar efeitos externos tais como o ângulo solar, o ângulo de visada e as interferências atmosféricas, de modo a permitir comparações espaciais e temporais;
- Normalizar efeitos internos, tais como variações no substrato abaixo do dossel, incluindo topografia (declividade e aspecto), solos, e diferenças quanto à vegetação senescente ou presença de ramos lenhosos (componentes não-fotossintéticos);
- Ser acoplável a algum parâmetro biofísico mensurável tais como biomassa, o IAF, ou a radiação fotossinteticamente ativa absorvida, para fins de validação e controle de qualidade.

2.7.1 NDFI – Índice Normalizado por Diferença de Fração

O NDFI – Índice Normalizado por Diferença de Fração é o índice utilizado pelo MapBiomass para diferenciar algumas classes de cobertura do solo nas classificações geradas a partir de imagens Landsat.

Plantios florestais e áreas queimadas possuem uma pequena proporção de vegetação sadia e uma elevada proporção de vegetação não-fotossinteticamente ativa (seca) e solo em comparação com florestas intactas. O teor de sombra das florestas degradadas também é maior em relação à floresta intacta (SOUZA et al., 2005). A fim de melhorar a degradação sinal causado pelo corte seletivo e queima, Souza et al. (2005), criaram NDFI, obtido a partir de modelos de análise de mistura espectral e representado pelas Equações 1 e 2:

$$NDFI = \frac{VEG_{normalizada} - (NPV + SOLO)}{VEG_{normalizada} + NPV + SOLO} \quad (1)$$

$$VEG_{normalizada} = \frac{VEG}{(100 - SOMBRA) * 100} \quad (2)$$

Em que: VEG é a fração de vegetação, SOMBRA a fração sombra, $VEG_{normalizada}$ a fração vegetação normalizada, NPV a fração de vegetação não-fotossinteticamente ativa, ou vegetação seca, e SOLO a fração solo. Essas frações são obtidas a partir da decomposição linear do *pixel*.

Os valores do índice NDFI variam de -1 a 1. Na teoria, são esperados valores elevados do índice para a floresta intacta (próximos a 1) devido à combinação dos valores elevados da vegetação normalizada (vegetação sadia e sombra do dossel) com baixos valores de vegetação seca e solo. A medida que a floresta vai se degradando, espera-se valores mais elevados para a vegetação seca e solo, o que diminui os valores do NDFI relacionados à floresta intacta. Assim, o NDFI tem o potencial de aprimorar a detecção da degradação florestal provocada por queimadas e exploração de madeira. O NDFI tem a vantagem de combinar, em uma única banda sintética, todas as informações que se mostraram relevantes para identificar e mapear florestas degradadas na região Amazônica, por exemplo.

2.8 Efeitos Atmosféricos

Tanto a radiação emitida pelo Sol como a refletida pela Terra passam através da atmosfera (MENESES, 2012). Em ambos os processos, ela interage com diferentes gases atmosféricos, (vapor d'água, dióxido de carbono, ozônio, entre outros.) assim como materiais particulados suspensos, tais como aerossóis e partículas de poeira. Durante essa interação, a radiação é parcialmente espalhada, absorvida e transmitida. De acordo com Meneses (2012), do total do fluxo da radiação que incide na superfície terrestre, 47% é absorvido pelos materiais nela presentes, 17% pela atmosfera e 37% é refletido pela Terra (incluindo nuvens e atmosfera. O grau da interação da radiação com a atmosfera depende essencialmente da sua trajetória e do seu comprimento de onda.

A distância percorrida pela radiação depende da localização da fonte de energia (alvo) e da altitude da plataforma do sensor. De acordo com Meneses (2012), a atenuação da radiação devido à sua interação com a atmosfera também depende do comprimento de onda, uma vez que alguns comprimentos de onda são transmitidos com uma eficiência maior, enquanto outros são mais suscetíveis aos efeitos de espalhamento e absorção atmosféricos. Um sensor remoto capta tanto a radiação total oriunda da superfície do solo, quanto àquela degradada pelos efeitos atmosféricos. A parte do sinal emanado pela atmosfera é denominada radiância ascendente, enquanto a proveniente do solo é denominada radiância de superfície. A radiância ascendente tende a mascarar o sinal do solo e atuar como um ruído de fundo.

A transmissividade da atmosfera em um dado comprimento de onda é uma medida da fração da radiância que emana da superfície terrestre e passa através da atmosfera sem interagir com ela (MENESES, 2012). A transmissividade varia de 0 a 1 e é inversamente relacionada a outro atributo denominado espessura óptica da atmosfera, que descreve a eficiência da atmosfera em bloquear a radiação da superfície terrestre por absorção ou espalhamento. Assim, verifica-se que a atmosfera atua como dispersora ou absorvedora da radiação emanada pela superfície terrestre. Além disso, a atmosfera também atua como fonte de radiação devido ao seu estado termal. Assim, as interações atmosfera-radiação podem ser agrupadas em três processos físicos: espalhamento, absorção e emissão.

2.8.1 Espalhamento Atmosférico

O espalhamento (difusão ou dispersão) refere-se à mudança aleatória da direção de propagação da radiação solar devido à sua interação elástica com os componentes atmosféricos (ZULLO JR, 1994). Essas interações são consideradas como um espalhamento elástico, que dispersam a radiação em todas as direções, não provocando alterações no seu comprimento de onda. Esse efeito atenua o sinal recebido pelo sensor e está presente em todos os comprimentos de onda do espectro eletromagnético (LATORRE et al., 2002). De acordo com Liou (1980), na atmosfera, o espalhamento ocorre desde pequenas moléculas de gases até grandes gotas ou partículas de gelo, sendo sua intensidade atribuída à razão entre o

tamanho da partícula e o comprimento de onda incidente. Existem, basicamente, dois tipos de espalhamento: seletivo, no qual se destacam os espalhamentos *Rayleigh* e *Mie*, e não-seletivo.

Em relação ao espalhamento seletivo, o mais comum é o espalhamento *Rayleigh*, também conhecido como espalhamento atmosférico molecular, cujo tamanho predominante das partículas (geralmente moléculas de gases e micropartículas constituintes da atmosfera) é muito menor que o comprimento de onda incidente. De acordo com Latorre et al. (2002) o espalhamento molecular é definido por meio dos perfis atmosféricos da pressão (hPa), temperatura (K), densidade de vapor d'água (g/m^3) e da densidade de ozônio (g/m^3). Esse tipo de espalhamento é mais severo nas porções ultravioleta e azul do espectro e é insignificante em comprimentos de onda menores que $1 \mu\text{m}$, sendo também responsável pela cor azul do céu e uma das causas primárias da "névoa" que reduz o contraste ao ser observada em algumas imagens.

Outro tipo de espalhamento é aquele que ocorre quando as partículas suspensas são esféricas e grossas, e cujo tamanho seja maior que o comprimento de onda incidente. Trata-se do espalhamento atmosférico por aerossóis ou do tipo *Mie*. Dessa forma, de acordo com Zullo Jr. (1994), é observado um espalhamento de 10% do total da radiância considerando condições atmosféricas normais e numa tomada perpendicular à superfície. As partículas de poeira suspensas e as moléculas de vapor d'água, que são mais relevantes em altitudes mais baixas da atmosfera, próximas à superfície terrestre, são as principais dispersoras desse tipo de espalhamento. Além disso, os efeitos causados por esses particulados dependem de suas características físicas, tais como: o tamanho e a forma da partícula, o índice de refração do objeto e a distribuição de suas concentrações. O espalhamento *Mie* influencia toda a região do espectro do ultravioleta próximo até o infravermelho próximo, e possui um efeito maior em comprimentos de onda maiores que o espalhamento de *Rayleigh*. A forte influência do vapor d'água, inclusive, faz com que esse tipo de espalhamento se manifeste em maior intensidade em ambientes nublados.

O espalhamento não-seletivo ocorre, de acordo com Meneses (2012), quando o tamanho das partículas supera o tamanho do comprimento de onda no intervalo do visível ao termal ($0,4$ a $1,4 \mu\text{m}$). Daí vem o fato de ser denominado de não-seletivo em relação ao tamanho da onda. Esse tipo de espalhamento ocorre em atmosferas

muito densas, com neblinas e nuvens, e acaba resultando em atenuações severas da radiação refletida pelos alvos ao sensor (MENESES, 2012). O espalhamento não-seletivo faz com que a cor das nuvens seja branca, uma vez que elas espalham a radiação para cima com alta intensidade.

2.8.2 *Absorção Atmosférica*

Liou (1980) destaca que o espalhamento geralmente é seguido de absorção. A absorção é um fenômeno termodinâmico que implica na perda efetiva de energia para constituintes atmosféricos. Os gases atmosféricos absorvem seletivamente a radiação eletromagnética em comprimentos de onda específicos, mas não deixa de abranger todo o espectro óptico. Tal processo exercerá grande influência nos sensores cujas bandas compreendam os comprimentos de absorção dos constituintes atmosféricos. Para os sensores hiperespectrais esse efeito é maior, uma vez que eles abrangem regiões espectrais de forte absorção, as quais são geralmente desprezadas nos sensores multiespectrais.

A absorção, em termos atmosféricos, pode ser considerada um dos efeitos mais prejudicial ao sensoriamento remoto. Em vários comprimentos de onda a atmosfera mostra-se parcial ou totalmente opaca às passagens da radiação solar e da radiação emitida pela Terra, em razão da absorção pelos gases nela presentes. Como consequência, a radiação solar pode ser impedida de atingir a superfície terrestre ou no mínimo sua intensidade é atenuada, o mesmo acontecendo com a radiação emitida pela Terra. Dessa forma, o sensor colocado no espaço ficará impedido de obter imagens da superfície terrestre nesses comprimentos de onda. Esses intervalos de comprimentos de onda são chamados de bandas de absorção da atmosfera e são proibitivos para o uso de sensoriamento remoto.

Os átomos e moléculas de gases possuem certos estados específicos de energia (rotacional, vibracional e níveis eletrônicos de energia). Energias de fótons de algumas radiações podem ser suficientes para provocar mudanças toleráveis dos níveis de energia nas moléculas de gás, levando a uma absorção seletiva da radiação eletromagnética. As principais bandas moleculares de absorção ou de emissão de radiação são resultantes das transições de energia rotacional e vibracional, bem como de suas interações (LATORRE et al., 2002). Entretanto,

conforme salientado por Liou (1980), as energias de transição rotacional e vibracional são menores que as energias dos processos de transição eletrônica.

Grande parte dos gases atmosféricos não produz feições de absorção entre 0,4 e 2,5 μm em condições normais da atmosfera. Os únicos que produzem feições observáveis são, de acordo com Gao et al. (1993): H_2O , CO_2 , O_3 , N_2O , CO , CH_4 e O_2 . As regiões do espectro de menor absorção são denominadas janelas atmosféricas, uma vez que podem ser usadas para observar fenômenos da superfície terrestre a partir de plataformas aéreas ou espaciais em toda a atmosfera. Importantes janelas atmosféricas disponíveis para detecção espacial constam na Figura 6. A porção visível do espectro é marcada pela presença de uma excelente janela atmosférica.




Figura 6 - Janelas Atmosféricas mais importantes

Ao observar a Figura 6 é possível perceber que a região de maior absorção, e sem uso do sensoriamento remoto, é no intervalo espectral termal de 14 μm em diante, devido à total absorção da radiação pelo vapor d'água atmosférico. Em contrapartida, na região das micro-ondas a atmosfera é quase 100% transparente. No intervalo do visível ao infravermelho, que é a região espectral mais usada em sensoriamento remoto, a atmosfera também mostra a sua notável influência para estudos atmosféricos. Por exemplo, tem-se os comprimentos de onda de 1,4 μm e 1,9 μm , os quais indicam absorção de 100% da radiação solar pelas moléculas de vapor d'água, impedindo o uso do sensoriamento remoto nesses comprimentos de onda.

2.9 Correção Atmosférica

A atmosfera representa uma fonte de erro de distorções radiométricas que alteram a imagem por completo. Isso ocorre devido à presença de vapor d'água, aerossóis e demais gases atmosféricos, que provocam um distúrbio no sinal captado pelo sensor de diversas maneiras. Assim, a aplicação de métodos de correção atmosférica para “limpar” a imagem pode ser de grande relevância, contribuindo para minimizar o efeito dos distúrbios provocados pela atmosfera e permitindo a recuperação da radiância da superfície.

O processo de correção atmosférica é considerado por muitos autores como sendo essencial para o processamento de imagens orbitais, uma vez que minimiza a influência dos fatores que compõem a atmosfera terrestre (WEISS et al., 2015). Os principais efeitos observados nas imagens orbitais multiespectrais são a diminuição da faixa de valores digitais registrados pelo sensor, diminuição do contraste entre superfícies e alteração do brilho de cada ponto da imagem. Para verificar o resultado de uma correção atmosférica, deve-se observar as curvas de assinatura espectral de alvos conhecidos presentes na imagem.

Ponzoni et al. (2012) destacam que apesar de dados de reflectância aparente permitirem a realização de diversas operações aritméticas utilizando dados de imagens de diferentes bandas espectrais, para um mesmo sensor, ou para sensores diferentes, ainda assim não é possível a caracterização espectral de um objeto existente na superfície terrestre, uma vez que os efeitos atmosféricos são intrínsecos aos valores de reflectância. Com isso, faz-se necessária a eliminação ou minimização dos efeitos da atmosfera sobre os valores de reflectância aparente.

Ferramentas e técnicas de correção atmosférica vêm sendo desenvolvidas e aprimoradas de acordo com a demanda de dados e atualização dos sistemas sensores disponíveis. Como há constante renovação das plataformas orbitais com novos sensores, a atualização dos *softwares* proprietários, livres e de código aberto deve se manter constante. Com isso, esse pré-processamento digital é considerado imprescindível no âmbito de monitoramento da superfície terrestre, pois a calibração dos dados multiespectrais acaba sendo necessária para padronizar a escala radiométrica (SONG et al., 2001)

Autores como Mather (2004), por exemplo, enfatiza que a correção atmosférica é indispensável para o cálculo de índices espectrais, tais como NDVI, NDWI e NDSI a partir de duas ou mais bandas espectrais, considerando o fato de as bandas serem afetadas diferentemente pelo espalhamento atmosférico.

Os procedimentos de correção atmosférica desenvolvidos para imagens multiespectrais caracterizam-se por serem modelos do tipo ordinário discreto em que se obtém um único valor de correção para toda a cena estudada, com base na calibração linear. Não obstante, com o surgimento da espectroscopia de imageamento verificou-se uma tendência para modelos de correção atmosférica do tipo distribuído, utilizando a calibração linear ponderada, em que é realizado um tratamento específico *pixel a pixel* (CARVALHO JR., 2000).

Os métodos de correção atmosférica podem ser, basicamente, de dois tipos: empíricos e físicos. O primeiro utiliza os números digitais existentes em *pixels*, que representam feições específicas referentes apenas às informações da própria imagem, a fim de que o nível dos efeitos atmosféricos em cada banda espectral seja aferido. O método físico, por sua vez, caracteriza-se pelo fato de as propriedades ópticas da atmosfera, assim como a dinâmica do processo de interação da radiação com a atmosfera e com a superfície possuírem papel fundamental para a sua aplicação. (ENVI, 2009).

Esses métodos estão baseados na teoria da transferência radiativa (BERK et al., 2002), com o objetivo de corrigir os efeitos atmosféricos considerando a complexidade da atmosfera. Dos modelos existentes e disponíveis em softwares de processamento de imagens de sensoriamento remoto destacam-se: 5S, 6S, LOWTRAN e MODTRAN, sendo esse último responsável pela origem do FLAASH (BERK et al., 2002), utilizado neste estudo.

O *Moderate Resolution Atmospheric Radiance and Transmittance Model* (MODTRAN) foi criado para aumentar a resolução espectral do LOWTRAN e foi incrementado com um modelo de banda molecular mais sensível (BERK et al., 2002). Ele processa dados de sensores hiperespectrais e multiespectrais nas faixas do infravermelho de ondas curtas (SWIR), visível e ultravioleta, minimizando os efeitos do espalhamento e absorção atmosféricos (ANDERSON et al., 1995).

Ao longo do tempo, o MODTRAN tem passado por constantes atualizações, o que permitiu a melhoria e otimização do seu desempenho. Ele possui quatro versões, sendo que a mais atual, MODTRAN 4, contém algoritmos que aumentam a

capacidade de predição dos efeitos atmosféricos em ambiente nublado e/ou aerossóis pesados (BERK et al., 2002; ADLER-GOLDEN et al., 1999).

2.9.1 QUAC

O *Quick Atmospheric Correction* (QUAC) é um método semi-empírico de correção atmosférica que permite a recuperação da profundidade óptica dependente do comprimento de onda do aerossol ou da neblina e absorvedores moleculares. O algoritmo foi apresentado pela primeira vez por Bernstein et al. (2004) durante um *Workshop* do AVIRIS. Ele permite a recuperação de espectros de reflectância aproximada, mesmo quando o sensor não possui uma calibração radiométrica ou de comprimento de onda adequada, ou quando a intensidade da iluminação solar é desconhecida. A velocidade computacional é muito mais rápida em comparação à maioria dos métodos de correção atmosférica, tornando-a potencialmente adequada para aplicações em tempo real. O QUAC assume uma relação linear entre a reflectância espectral e a radiação medida.

O QUAC realiza uma correção atmosférica rápida e bastante precisa com dentro das seguintes condições: (1) existência de pelo menos 10 materiais diferentes em uma cena; e (2) existência de *pixels* suficientemente escuros em uma cena para permitir uma boa estimativa do espectro de linha de base (BERNSTEIN et al., 2004)

Ainda de acordo com o que o autor descreve ao falar do algoritmo, a principal premissa do QUAC, que é empiricamente válida para a maioria das cenas, é que a média de diversos espectros de reflectância de referência (*endmembers*), com exceção de materiais altamente estruturados (vegetação, águas rasas, solos muito úmidos, etc.), é sempre a mesma. Mais especificamente, cada imagem deve conter pelo menos uma quantidade de materiais espectralmente diferentes cujo espectro de reflectância médio pode ser tomado como uma “referência universal”. Os materiais podem incluir materiais naturais e artificiais, como um campo de sujeira, um corpo de água, rochas, carros, telhados ou estradas. É incomum que esta condição de diversidade material não seja atingida, mas pode vir a acontecer. Por exemplo, em algumas cenas de todos os cursos d’água ou de todo o deserto. No entanto, essa imagem é tipicamente de interesse muito menor para o sensoriamento remoto.

Com base no número e localização das bandas de comprimento de onda na imagem, o QUAC pode identificar o sensor associado ou um substituto suficientemente próximo para o processo de correção. Embora novos sensores possam ser facilmente adicionados ao QUAC, isso acaba não sendo necessário, uma vez que o processo de correção atmosférica depende apenas das propriedades da classe do sensor (BERNSTEIN et al., 2004).

O cálculo da compensação (offset) envolve uma série de etapas de condicionamento de dados para garantir que uma linha de base válida seja determinada. Isto inclui: (1) a remoção de *pixels* de borda; (2) a média de *pixels* adjacentes em uma linha; (3) rejeição de valores ≤ 0 ; e (4) a mediana da filtragem de *pixels* adjacentes para remover artefatos de pico. Esse módulo também encontra um valor máximo em um único canal espectral próximo ao pico do espectro de referência (BERNSTEIN et al., 2012). Conforme discutido anteriormente, esse valor máximo é usado para converter os dados para unidades de reflectâncias aproximadas antes da seleção do *endmember*.

Ainda de acordo com Bernstein et al. (2012), antes da seleção do *endmember*, os dados são convertidos para uma escala aproximada de reflectância 0-1, dividindo pelo valor máximo acima mencionado e uma curva de corpo negro solar aproximada normalizada à unidade em seu valor de pico. Não é necessário, nem desejável, usar a curva de corpo negro solar exata. A temperatura solar é ajustada para produzir curvas de reflectância aproximadas que abrangem aproximadamente a mesma faixa de valores em todo o domínio espectral do sensor. A temperatura solar efetiva varia entre 4000 e 4500 K, dependendo do tipo de sensor, considerando a temperatura real do Sol no valor de 5700 K. Existem duas razões importantes para realizar a transformação para uma escala de reflectância (BERNSTEIN et al., 2012): (1) simplificar o processo de fixação de limiares de filtros dependentes do espectro, uma vez que todos os sensores são colocados numa escala comum, e (2) assegurar que todas as regiões espectrais são comparadas – habilmente ponderadas no processo de seleção de *endmembers*. O último é particularmente importante porque mantém a consistência com a seleção de *endmembers*, que é baseada em valores de reflectância.

Conforme destacado por Bernstein et al. (2012), os espectros que podem introduzir características e desvios indesejáveis na curva de ganho são filtrados. O exemplo mais comum é a vegetação, que tem uma borda vermelha em rápida

ascensão em torno de 700 nm. A vegetação está presente nas cenas na maioria das vezes e apresenta grande variabilidade espectral, o que significa que muitos espectros de vegetação seriam selecionados como *endmembers*. Isso produziria uma feição de borda forte na curva de ganho em torno de 700 nm e resultaria em desequilíbrio no ganho para cada lado da borda do vermelho. No entanto, a borda do vermelho facilita a implementação de um filtro de vegetação baseado no índice de vegetação por diferença normalizada (NDVI), proposto por Rouse et al. (1973), para cada *pixel*.

No QUAC os *pixels* com $NDVI > 0,17$ são descartados. Solos úmidos ou águas muito rasas também podem causar um problema semelhante e são filtradas com base em no índice de umidade por diferença normalizada (NDMI), proposto por Wilson e Sader (2002), onde os *pixels* são descartados para NDMI com valores $> 0,3 - 0,5$ (dependendo do sensor).

Como a localização da borda azul da umidade a aproximadamente 900 nm pode variar, dependendo da concentração das partículas, foi implementado um filtro de umidade. No futuro, se outros materiais comuns e abundantes apresentarem um problema, é simples construir e adicionar um novo filtro, uma vez que os autores consideram ser fácil reconhecer quando o problema existe, já que muitas amostras do material indesejado estarão presentes nos espectros dos *endmembers* corrigidos.

Antes do processamento do *endmember*, a imagem é dividida em parcelas menores. Isso ocorre porque as imagens completas podem ser muito grandes para a memória disponível, o que pode retardar a velocidade do processamento. Bernstein et al. (2012) enfatizam que depois de tentar uma série de estratégias de fragmentação, a melhor solução é dividir cada cubo de dados em 50 fragmentos e encontrar 20 *endmembers* para cada fragmento, o que resulta num total de 1000 fragmentos de *endmembers* disponíveis para a seleção do subconjunto final de *endmembers* usados na curva de ganho. Atualmente, usa-se 50 *endmembers*. Antes da determinação final dos *endmembers* da cena, é feita uma filtragem dos *pixels* excessivamente brilhantes devido a reflexos e saturação do canal. Isso é conseguido por meio de um filtro de mediana aplicado a cada canal. Se qualquer valor de canal de um espectro de extremidade é $> 2,25$ vezes o seu valor mediano, então esse *endmember* é excluído do processo de seleção final.

2.9.2 Algoritmo FLAASH

O *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) é um módulo de correção atmosférica baseado no MODTRAN e desenvolvido por meio de uma parceria entre a *Air Force Phillips Laboratory, Hanscom AFB* e *Spectral Sciences, Inc.* com a finalidade de eliminar os efeitos provocados pelo espalhamento e absorção atmosféricos para obtenção dos valores de reflectância dos alvos imageados por sensores multiespectrais e hiperespectrais. O FLAASH foi escrito em linguagem IDL (*Interactive Data Language*) visando a compatibilidade com uma grande variedade de plataformas computacionais e para facilitar seu uso a partir de softwares de visualização/análise, como o ENVI, por exemplo.

De acordo com Adler-Golden et al. (1999), dentre os seus principais objetivos destacam-se: (1) fornecer precisão, baseada na derivação física das propriedades superficiais e atmosféricas, tais como albedo, altitude, coluna de vapor d'água, profundidades ópticas de aerossóis e nuvens, e temperaturas atmosféricas; (2) tempo mínimo exigido para execução; e (3) interface interativa e de fácil utilização para executar cálculos arbitrários do MODTRAN.

O algoritmo utiliza a precisão completa do MODTRAN4 e considera os efeitos adjacentes associados ao espalhamento atmosférico. Além disso, uma ordem de redução da magnitude no tempo de cálculo é alcançada usando a opção de resolução mais baixa do MODTRAN (15 cm^{-1}) (ADLER-GOLDEN et al., 1999).

Para realizar a correção atmosférica, o FLAASH requer a inserção de alguns dados como vapor d'água, hora e data do imageamento, definição do algoritmo de espalhamento, ângulo azimutal e de elevação do sensor, entre outros. Além disso, ele pode ser utilizado para corrigir imagens que estejam dentro do espectro do visível até o infravermelho médio, na região de $3 \mu\text{m}$.

Com relação ao modelo atmosférico, para se obter os melhores resultados, deve ser selecionado um modelo cuja quantidade padrão de vapor d'água presente na coluna de ar atmosférico seja similar ou um pouco maior que a esperada para a cena. A Tabela 2 apresenta as quantidades padrão de vapor d'água na coluna de ar para cada modelo atmosférico. Cabe destacar que a temperatura superficial se refere à temperatura atmosférica próxima à superfície terrestre (GROTZINGER e JORDAN, 2013).

Tabela 2 - Quantidades de vapor d'água na coluna de ar atmosférico e temperaturas do ar de superfície para os modelos atmosféricos do MODTRAN

Modelo Atmosférico	Vapor d'água (atm-cm)	Vapor d'água (g/cm²)	Temperatura Superficial
Inverno subártico (ISA)	518	0,42	-16°C ou 3°F
Inverno de média latitude (IML)	1060	0,85	-1°C ou 30°F
Padrão Americano (EUA)	1762	1,42	15 °C ou 59°F
Verão subártico (VSA)	2589	2,08	14°C ou 57°F
Verão de média latitude (VML)	3636	2,92	21°C ou 70°F
Tropical (T)	5119	4,11	27°C ou 80°F

Adaptado de ENVI for FLAASH (2005)

Se não estiver disponível a informação sobre o vapor d'água, um modelo atmosférico deverá ser selecionado de acordo com a temperatura do ar de superfície conhecida ou esperada, a qual tende a estar correlacionada com o vapor d'água. Se a temperatura é desconhecida, o modelo atmosférico deverá ser selecionado baseado na dependência latitudinal/sazonal da temperatura do ar de superfície.

Tabela 3 - Seleção do Modelo Atmosférico baseado na dependência Latitudinal/Sazonal da temperatura da superfície

Latitude (°N)	Jan.	Março	Maio	Julho	Set.	Nov.
80	ISA	ISA	ISA	IML	IML	ISA
70	ISA	ISA	IML	IML	IML	ISA
60	IML	IML	IML	VSA	VSA	IML
50	IML	IML	VSA	VSA	VSA	VSA
40	VSA	VSA	VSA	VML	VML	VSA
30	VML	VML	VML	T	T	VML
20	T	T	T	T	T	T
10	T	T	T	T	T	T
0	T	T	T	T	T	T
-10	T	T	T	T	T	T
-20	T	T	T	VML	VML	T
-30	VML	VML	VML	VML	VML	VML
-40	VSA	VSA	VSA	VSA	VSA	VSA
-50	VSA	VSA	VSA	IML	IML	VSA
-60	IML	IML	IML	IML	IML	IML
-70	IML	IML	IML	IML	IML	IML
-80	IML	IML	IML	ISA	IML	IML

Adaptado de ENVI for FLAASH (2005). Siglas disponíveis na Tabela 2.

O modelo de aerossol está relacionado com a visibilidade horizontal no momento em que o sensor registra a imagem, no entanto a diferença entre esses modelos está vinculada à quantidade de aerossóis existente para as diversas situações. Esta visibilidade é caracterizada por uma distância na horizontal a qual depende da quantidade de aerossóis. O conceito de visibilidade está associado à distância horizontal em que se consegue visualizar um objeto a olho nu. Os vários modelos utilizados no FLAASH são:

- Rural – representa áreas onde os aerossóis encontrados não são afetados fortemente por zonas urbanas e fonte industrial;
- Urbana – uma mistura de 80% de aerossol rural com 20% de áreas urbanas de alta densidade e com presença de áreas industriais;
- Marítimo – representado pela camada limitada pelos oceanos ou costas litorâneas que recebem diretamente o vento proveniente do oceano;
- Troposférico – usado em situações de boa visibilidade em que se consegue uma visibilidade em torno de 40 km sobre a superfície.

Os modelos Rural, Urbano e Marítimo são caracterizados pela presença de aerossóis em massas de ar que estão situadas nestas regiões. Já o modelo troposférico é caracterizado por uma visibilidade muito elevada em relação aos demais, existindo a possibilidade de não usar os modelos de aerossóis desde que se opte por esta situação (ENVI FLAASH, 2005).

2.10 Processamento Digital de Imagens (PDI)

O termo processamento digital de imagens está ligado à manipulação de uma imagem de computador de modo que a entrada e saída do processo sejam imagens. O processamento envolve uma série de atividades interconectadas. Após a captura da imagem pelo sensor, a imagem precisa ser representada adequadamente para ser submetida a um tratamento computacional. O primeiro passo efetivo de processamento é comumente conhecido como pré-processamento, o qual envolve passos como a filtragem de ruídos introduzidos pelos sensores e a correção de distorções geométricas causadas pelo sensor (QUEIROZ e GOMES, 2001). Ainda de acordo com os autores, o PDI envolve fundamentos de várias ciências, os quais

são comumente requeridos no projeto de um sistema de processamento de imagens.

2.10.1 Modelo Espectral de Mistura

A resposta espectral de um *pixel* é o resultado da mistura da resposta espectral dos materiais que foram este *pixel* a não ser que dentro dele esteja presente exclusivamente um único material. Essa mistura espectral ocorre em todas as escalas, desde a escala microscópica de grãos minerais, na qual a mistura é tipicamente não-linear, até a escala macroscópica (quilômetros), como classes de cobertura de solo (PONZONI e SHIMABUKURO, 2007).

Os mesmos autores afirmam que o valor associado a cada *pixel* de uma imagem representa a radiância média dos materiais presentes na superfície em uma determinada banda espectral, somada a interferência da atmosfera. A radiância registrada pelo sensor depende das características do sensor (resolução espacial), das propriedades físico-químicas dos materiais presentes no *pixel* e da interferência atmosférica. De certa forma, essa mistura espectral é indesejada, pois mascara a resposta característica de cada alvo, dificultando a aplicação das técnicas de classificação digital de imagens orbitais que se fundamentam exclusivamente no domínio espectral (radiométrico), pois estas consideram que um dado *pixel* contém uma medida de radiância de um único objeto.

A mistura não-linear ocorre devido ao espalhamento múltiplo, em que um mesmo fóton interage com mais de um alvo, podendo-se tornar expressiva em superfícies com cobertura vegetal (copas de árvores) e solos (HUETE, 1986).

A análise de Mistura Espectral (*Spectral Mixture Analysis – SMA*), proposta por Smith et al. (1985), é um modelo linear baseado na mistura espectral de dois ou mais componentes ou *endmembers* (ADAMS et al., 1993), que permite representar a variabilidade na composição e iluminação de uma imagem. Os *pixels* da imagem são modelados como a mistura linear de *endmembers*, onde, um *endmember* de sombra é utilizado para representar a variação de iluminação, e um ou mais *endmembers* (não-sombra) para representar os diferentes materiais da imagem.

Na MEM, a reflectância do *pixel* (ρ'_λ) é determinada pela soma das reflectâncias de cada material contido no *pixel*, multiplicado pela fração de cobertura (Equação 3):

$$\rho'_\lambda = \sum_{i=1}^N f_i * \rho_{i\lambda} + \varepsilon_\lambda \quad (3)$$

Em que: $\rho_{i\lambda}$ é a reflectância do *endmember* i para uma banda específica (λ), f_i é a fração do *endmember*, N é o número de *endmembers* e ε_λ é o erro residual.

Como a soma das proporções, para qualquer resolução, deve ser igual a um, as frações modeladas dos *endmembers* são restringidas por:

$$\sum_{i=1}^N f_i, \text{ onde } 0 \leq f_i \leq 1 \quad (4)$$

O ajuste do modelo é avaliado pelo seu erro residual (ε_λ) ou Raiz do Erro Médio Quadrático (*Root Mean Square Error* – RMSE).

$$RMSE = \sqrt{\frac{\sum_{\lambda=1}^M (\varepsilon_\lambda)^2}{M}} \quad (5)$$

Em que: M é o número de bandas. Cabe ressaltar que o SMA tipicamente assume somente interações entre fótons e superfícies, produzindo uma mistura linear das frações de superfície e seus valores de reflectância.

A partir da aplicação do algoritmo de mistura são geradas tantas imagens quantos forem as componentes puras identificadas pelo modelo. No caso específico do modelo desenvolvido por Shimabukuro e Smith (1991), são consideradas componentes puras de um *pixel* de imagem do sensor TM do Landsat-5 a vegetação, a sombra e o solo, sendo possível, portanto, decompor cada *pixel* de uma imagem nas proporções de sombra, vegetação e solo que o compõe. Essas imagens são conhecidas por imagens-fração ou proporção, um número variável de acordo com o número de elementos selecionados como constituintes da mistura espectral (VASCONCELOS e NOVO, 2004).

A seleção de *pixels* candidatos a *endmembers* é essencial para o bom desempenho de modelos de mistura, já que estes representarão toda a informação espectral contida na cena (TOMPINKS et al., 1997). O conjunto ideal de *endmembers* deve apresentar espectros que, quando combinados linearmente, sejam capazes de reproduzir qualquer espectro da cena sob análise. Os *endmembers* podem ser selecionados de *pixels* puros da própria imagem, medidos em campo ou laboratório, ou então criados como *endmembers* virtuais (ADAMS et al., 1993). Rashed et al. (2003) recomendaram obter os componentes da própria imagem, pois, dessa forma, há compatibilidade com a resolução espacial da imagem, tornando mais fácil associá-los às feições na cena. Típicos *endmembers* usados na MEM incluem solo, vegetação verde (*Green Vegetation – GV*), vegetação não-fotossinteticamente ativa (*Nonphotosynthetic Vegetation – NPV*) e sombra.

2.10.2 Classificação Digital de Imagens

Classificação é o processo de extração de informação em imagens para reconhecer padrões e objetos homogêneos. Os métodos de classificação são usados para mapear áreas que apresentam um mesmo significado em imagens de satélite (KÖRTING, 2006). Segundo Liotte & Macedo (2000), o objetivo da classificação é a substituição da análise visual da imagem por técnicas de identificação automática de feições da cena. Com isso, os valores de refletância de cada *pixel* são agrupados em classes com valores similares. Este agrupamento em classes de padrões de respostas similares envolve a análise de dados multiespectrais e a aplicação de regras de decisão baseadas em estatísticas.

De acordo com Bernardes et al. (2005), duas abordagens distintas são adotadas na classificação automática de imagens: classificação supervisionada e não supervisionada. A classificação supervisionada é realizada utilizando como base um conjunto de amostras de treinamento coletado pelo analista. Quando não for possível definir áreas representativas para o treinamento, podem ser utilizados algoritmos baseados em regras estatísticas capazes de fazer o reconhecimento das classes presentes na imagem, o que configura uma classificação não supervisionada.

A Classificação Supervisionada depende do conhecimento prévio do usuário sobre a área, podendo ser adquirido por meio de trabalhos de campo, relatórios, fotografias aéreas, dentre outros (MATHER, 2004). O processo de classificação consiste em dois estágios: reconhecimento na imagem dos objetos do mundo real (categorias) e, segundo, rotulação dos *pixels* para serem classificados. Entre várias formas de reconhecimento destas categorias, Florenzano (2002), sinaliza que aspectos como tonalidade, tamanho, textura, padrão e localização podem ser levados em consideração ao classificar o alvo. Portanto, pode-se dizer que a classificação de imagens busca reconhecer padrões (espaciais, espectrais e temporais) e categorizar, automaticamente, todos os *pixels* dentro de classes de cobertura do solo ou temas (LILLESAND E KIEFER, 1994).

Porém, mesmo o usuário tendo efetuado boa coleta de *pixels* para as amostras, existem algumas limitações na técnica de classificação supervisionada (NOVO, 1995): (1) algumas classes de interesse não têm, naturalmente, um comportamento espectral homogêneo em toda a sua extensão espacial, como ocorre, por exemplo, em áreas urbanas; (2) duas classes podem conter os mesmos objetos em proporções diferentes; e (3) duas classes distintas podem apresentar comportamento espectral semelhante.

Na prática a classificação de um determinado uso do solo é feita com base em uma amostra contendo as respostas espectrais deste uso. Isso é necessário, pois ocorrem variações na energia refletida por diferentes *pixels* do mesmo alvo, variação esta atribuída à mistura dos materiais, iluminação da cena no momento da passagem do satélite, ruídos e outras imperfeições que prejudicam a qualidade de alguns *pixels*.

Ao se analisar as respostas espectrais de dois materiais diferentes há de se considerar o risco de ocorrer a sobreposição das respostas espectrais em duas bandas, impossibilitando assim a separação dos mesmos com base nestas duas bandas. Desta forma, a introdução de uma nova banda faz-se necessária para garantir a possibilidade de classificação. Quanto maior o número de bandas maior será a precisão na classificação.

2.11 Avaliação da Qualidade dos Dados

Há basicamente duas formas de se avaliar a acurácia de um mapa: a posicional e a temática. Enquanto a primeira lida com a acurácia da posição das feições do mapa, assim como a medição do quão distante uma feição no mapa está da sua posição real, a segunda lida com as classes atribuídas às diferentes feições presentes no mapa, avaliando o quanto as classes mapeadas se diferem ou se assemelham à realidade. De acordo com Congalton e Green (2008), as avaliações de acurácia incluem três passos fundamentais: 1 – o desenho da amostragem de avaliação da acurácia; 2 – a coleta de dados para cada amostra; e 3 – a análise dos resultados.

Geralmente recomenda-se a aplicação de algum processo de avaliação da exatidão da classificação. Para medir sua eficiência, ou em outras palavras validar a classificação, é necessário o uso de verdades de campo (áreas testes definidas para avaliar a classificação) que consiste em coletar em campo, ou a partir de outro artifício que tenha a mesma finalidade, dados referentes às regiões classificadas que posteriormente possam ser comparados com os resultados da classificação. São várias as técnicas para avaliar a exatidão da classificação, entre elas podemos citar: as técnicas baseadas em Matriz de Confusão, técnicas *Fuzzy*, características operador-receptor, entre outras (MOREIRA, 2001).

2.11.1 Matriz de Confusão

Independentemente da aplicação ou não de algum processo de agrupamento ou filtros para melhorar a classificação, é necessário avaliar os resultados da classificação para medir a eficácia do método utilizado e determinar o grau de erro do produto final. Isto pode ser feito com o uso da Matriz de Confusão ou por meio da estimativa de erros, a qual se destaca pela utilização de uma matriz composta por linhas e colunas e que indica a correspondência entre as classes na verdade de campo e no mapa. Segundo Congalton e Green (2008), a matriz de confusão é uma maneira muito eficaz para representar a precisão do mapeamento, indicando sua confiabilidade, porém uma vez que é mal construída, toda análise torna-se insignificante.

A Matriz de Confusão é composta por elementos na diagonal principal que expressam a quantidade de *pixels* que foram classificados corretamente (n_{ii}), e elementos fora da diagonal que expressam tanto a quantidade de *pixels* que foram incluídos erroneamente em uma classe (erro de comissão), assim como a quantidade de *pixels* que foram excluídos erroneamente de uma classe (erro de omissão). Essa matriz mostra o quanto o classificador de imagens confunde uma classe com outra. A Figura 7 apresenta a estrutura de uma matriz de confusão. Portanto, os seguintes fatores devem ser considerados para a construção de uma matriz correta: padrão, unidade e número de amostras. Estes fatores fornecem informações essenciais para a avaliação de uma matriz.

		j = Colunas (Referência)			Total de Linhas n_{i+}
		1	2	k	
i = Linhas (Classificação)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total de Colunas n_{+i}		n_{+1}	n_{+2}	n_{+k}	n

Figura 7 - Estrutura de uma Matriz de Confusão. Fonte: Passo (2013)

2.11.2 Padrão, unidade e número de amostras

Padrão de amostragem é a maneira, em termos espaciais, em que as amostras são tomadas em uma dada área (BRITES et al., 1996-a). Em sensoriamento remoto, estes padrões são de fundamental importância, pois dependendo da forma como são dispostos podem incorrer na incorporação de amostras com alta correlação espacial.

Dentre os padrões de amostragem têm-se, de acordo com Brites et al. (1996-a): amostragem totalmente casualizada, onde todos os indivíduos possuem igual chance de serem selecionados; amostragem sistemática, onde a amostragem é feita por um processo probabilístico não casualizado, onde seu critério de probabilidade se estabelece por meio da aleatorização da primeira unidade amostral; amostragem sistemática estratificada, que combina propriedades da amostragem sistemática e da amostragem estratificada, propiciando a cobertura de toda a área de interesse e, simultaneamente, preservando a casualidade do procedimento.

Unidades de amostragem são as porções do mapa que serão selecionadas para avaliação da precisão. Existem quatro escolhas possíveis para a unidade de amostragem: (1) um único *pixel*, (2) um conjunto de *pixels* (muitas vezes um quadrado de 3x3 *pixels*), (3) um polígono (ou objeto) e (4) um conjunto de polígonos (CONGALTON & GREEN, 2008).

De acordo com Cadena (2011), normalmente duas estratégias podem ser usadas no sentido de calcular o número de amostras necessárias para computar a acurácia: a distribuição binomial e a multinomial. O modelo binomial é apenas apropriado para computar o número de amostras necessário para uma única classe visto que este simplesmente faz a distinção entre a classificação correta e incorreta e não leva em consideração o conjunto de classes analisadas. Por outro lado, na distribuição multinomial, o processo de validação não é uma questão apenas de certo ou errado, mas o erro deve ser classificado em relação ao total de possibilidades (ou conjunto de classes), de modo que o uso dessa distribuição implica no conhecimento *a priori* do número de classes.

Congalton e Green (2008) afirmam que a criação de uma matriz de erros não é simplesmente uma questão de correto ou incorreto (o caso binomial), mas sim uma questão de qual ou quais categorias de erros estão confusas. Portanto, o uso de uma distribuição binomial para a determinação do tamanho da amostra para uma matriz de confusão não é apropriado, mas sim uma distribuição multinomial, uma vez que esta leva em consideração o número de classes. Com base nisso, os autores apresentam a Equação 6 para determinação do número de amostras:

$$N = \frac{B\Pi_i(1 - \Pi_i)}{b^2} \quad (6)$$

Em que: **N** é o número de amostras; **B** é obtido de uma tabela de distribuição qui-quadrado com um grau de liberdade $1-\alpha/k$; **k** é o número de classes; $1-\alpha$ é o grau de confiança; Π_i é a proporção da classe com maior área no mapa; e **b** é o máximo erro admissível.

2.11.3 Coeficientes de concordância

Seguindo os critérios para a construção da matriz de confusão, a avaliação da acurácia pode ser obtida por meio de coeficientes de concordância derivados dela, sendo que estes podem ser expressos como concordância total ou para classes individuais (FIGUEIREDO E VIEIRA, 2007).

O coeficiente de concordância total mais utilizado, segundo Levada (2010), é a taxa de acerto ou Exatidão Global (HELLDEN E STERN, 1980). Porém, apenas o seu cálculo não é suficiente, havendo a necessidade de índices que levam em conta a matriz por completo, como os coeficientes de concordância *Tau* (KLECKA, 1980) e *Kappa* (COHEN, 1960).

Os coeficientes de concordância por classe avaliam as classes de forma individual. Dentre os métodos que mais se destacam na literatura, tem-se o *Kappa* condicional (BISHOP et al., 1975). A exatidão do usuário e do produtor foi introduzida em estudos de sensoriamento remoto por Story e Congalton (1986).

2.12.3.1. Exatidão Global

A taxa de acerto ou Exatidão Global (P_0) é calculada dividindo-se a soma dos valores da diagonal principal da matriz de confusão, que representa o número de amostras classificadas corretamente n_{ii} , pelo número total de amostras coletadas N , conforme demonstrado pela Equação 7 (HELLDEN et al., 1980):

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (7)$$

Em que: **M** é o número de categorias informacionais presentes na matriz de erros; n_{ii} referem-se aos elementos da diagonal principal, ou seja, elementos classificados corretamente; e **N** o número total de amostras.

Segundo Brites et al. (1996), o índice de exatidão global apresenta os maiores valores quando comparado a outros índices pelo fato de considerar apenas a diagonal principal da matriz de erros, ignorando a ocorrência de concordância casual entre as classes.

2.12.3.2. Coeficiente *Kappa*

Um subproduto da Matriz de Confusão, que auxilia na avaliação do classificador, é o Índice Kappa (*K*). Uma das vantagens alegadas para uso do Kappa é de que ele também incorpora a informação dos *pixels* mal classificados, e não apenas dos bem classificados como faz a Acurácia Global. O Índice Kappa é um método usado para avaliar a concordância entre a verdade terrestre e o mapa temático (IWAI, 2003).

O Índice Kappa é um dos parâmetros mais eficientes para se quantificar a exatidão de uma classificação de uso do solo. A estatística Kappa inclui todos os *pixels* da imagem, sejam aqueles classificados corretamente, ou aqueles classificados erroneamente (MOREIRA, 2001). Este índice pode ser calculado por meio da seguinte formulação matemática (Equação 8):

$$K = \frac{P_o - P_c}{1 - P_c} \quad (8)$$

Em que: P_o é a exatidão global (proporção de unidades que concordam); e P_c é a proporção de unidades que concordam por casualidade, representada pela Equação 9.

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2} \quad (9)$$

Em que: **M** é o número de classes; 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*; e **N** o número total de amostras.

O resultado da estatística *Kappa* normalmente é comparado aos valores contidos na Tabela 4, proposta por Landis e Koch (1977), com a finalidade de indicar a qualidade do mapa temático. Embora essa tabela tenha sido desenvolvida para analisar a qualidade de diagnósticos clínicos, a mesma tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto (PRADO, 2009).

Tabela 4 - Qualidade da classificação associada ao índice *Kappa*

Índice <i>Kappa</i>	Desempenho
<0	Péssimo
0<k≤0,2	Ruim
0,2<k≤0,4	Razoável
0,4<k≤0,6	Bom
0,6<k≤0,8	Muito Bom
0,8<k≤1,0	Excelente

Fonte: Adaptada de Landis e Koch (1977)

Segundo Brites et al. (1996), o índice *Kappa* é recomendado como uma medida apropriada para avaliar a exatidão porque não representa apenas os valores que se situam na diagonal principal da matriz, mas ela por inteiro, sendo esta uma forma padronizada para reportar erros em locais específicos.

2.12.3.3. Coeficiente *Tau*

O coeficiente de concordância *Tau* (τ) (KLECKA, 1980), ao contrário do coeficiente *Kappa*, baseia-se na probabilidade *a priori*, permitindo, assim, a obtenção do valor da concordância esperada (P_r), mesmo antes de efetuar a checagem dos resultados da simulação de mapeamento. Isso fornece uma clara indicação de como a classificação se comporta quando comparada com a atribuição casual dos *pixels* às categorias ou classes (BERNARDES et al., 2006). O coeficiente de concordância *Tau* pode ser determinado pela Equação 10.

$$\tau = \frac{P_o - P_r}{1 - P_r} \quad (10)$$

Em que: τ é o coeficiente *Tau*; P_o é a exatidão global (proporção de unidades que concordam); P_r equivale a $1/M$, onde M é o número de classes.

De acordo com Brites et al. (1996), *Tau* é um ajuste do percentual de concordância pelo número de categorias, e à medida que esse número aumenta, *Tau* se aproxima da percentagem do índice de exatidão global. Outro aspecto que merece ser destacado é o fato de a interpretação do coeficiente *Tau* ser ligeiramente diferente do *Kappa*, já que ele indica a percentagem de elementos (*pixels*) a mais que foi classificada corretamente em relação ao que seria esperado apenas pela sorte (LEVADA, 2010). Além disso, Antunes (2003) afirma que o coeficiente *Tau* mede o grau de concordância em escalas nominais, levando em consideração a independência das unidades, das classes ou categorias da escala nominal, que são também mutuamente exclusivas, e da operação do classificador e dos pontos de referência.

2.12.3.4. *Kappa* Condicional

Rosenfield e Fitzpatrick-Lins (1986) propuseram o *Kappa* condicional (K_i) como uma medida de precisão para categoria individual, baseado no índice *K* de Cohen (1960). O índice pode ser calculado conforme a Equação 11.

$$K_i = \frac{N \cdot n_{ii} - n_{i+} n_{+i}}{N \cdot n_{i+} - n_{i+} n_{+i}} \quad (11)$$

Em que: K_i é o *Kappa* Condicional; N é o número total de amostras; n_{ii} se refere aos elementos da diagonal, ou seja, aqueles classificados corretamente; n_{i+} é total de elementos classificados para uma categoria i ; n_{+i} é o total de elementos de referência amostrados para uma categoria i .

2.12.3.5. Exatidão do usuário e do produtor

Os erros de omissão (ϵ_0), que se tratam de amostras de uma classe específica que foram classificadas como outras, e os erros de comissão (ϵ_c), que por sua vez se tratam de classes classificadas como uma classe específica, servem como base para o cálculo das exatidões do produtor (e_p) e do usuário (e_u). A primeira é calculada a partir dos dados de referência, dividindo o número total de amostras corretamente classificadas em uma categoria pelo número de amostras que foram classificadas nessa categoria, ou seja, o total da coluna (STORY e CONGALTON, 1986), conforme mostra a Equação 12.

$$e_p = \frac{n_{ii}}{n_{+i}} \quad (12)$$

Em que: e_p é a exatidão do produtor; n_{ii} se refere aos elementos da diagonal, ou seja, aqueles classificados corretamente; e n_{+i} se refere ao total de elementos de referência amostrados para uma categoria i .

A exatidão do usuário (e_u), por sua vez, é calculada a partir dos dados da classificação, dividindo o número total de amostras corretamente classificadas em uma categoria pelo número de amostras que foram classificadas nessa categoria, ou seja, o total da linha (STORY e CONGALTON, 1986). A Equação 13 apresenta o cálculo.

$$e_u = \frac{n_{ii}}{n_{+i}} \quad (13)$$

Em que: e_u é a exatidão do usuário; n_{ii} se refere aos elementos da diagonal, ou seja, aqueles classificados corretamente; e n_{+i} se refere ao total de elementos de referência amostrados para uma categoria i .

2.12 Estado da Arte

Ribeiro et al. (2009) compararam dados com e sem correção atmosférica no estudo do estado de conservação da vegetação intra-urbana na cidade de São José dos Campos, onde verificaram maiores erros de omissão e comissão nos dados sem correção atmosférica. Gonçalves et al. (2015), por sua vez, procederam com a avaliação da classificação de uma imagem Landsat-8 na região do Pantanal com e sem correção atmosférica e notaram que a diferença não foi significativa entre os dados comparados.

Mandanici et al. (2015) fizeram uma comparação entre modelos de correção atmosférica, baseados em modelos empíricos e físicos, e relataram não ser possível qual método apresente maior acurácia, muito embora os autores destacaram que modelos tais como o FLAASH e QUAC destacam melhor a forma das assinaturas espectrais dos alvos, diferentemente dos empíricos, que melhor descrevem a variação de albedo.

Gomes et al. (2012) compararam os modelos FLAASH e DOS e verificaram resultados mais consistentes do FLAASH com dados de bibliotecas espectrais obtidas em campo. Guo e Zeng (2012) efetuaram uma análise de imagens do SPOT-5 antes e depois de aplicarem os métodos de correção atmosférica FLAASH e QUAC em diferentes cidades da China e constataram que ambos os métodos, mesmo com suas especificidades, podem eliminar efeitos atmosféricos e recuperar características típicas de diferentes feições superficiais de maneira mais eficiente, onde respondem ainda melhor para alvos vegetais. Ainda assim, os autores constataram maior acurácia do FLAASH em comparação ao QUAC, mas destacaram a maior conveniência do QUAC devido a sua maior independência em termos de preenchimento de parâmetros de entrada.

Carvalho e Baptista (2015) compararam dados RapidEye Ortho convertidos para reflectância de superfície por meio do FLAASH, com dados em reflectância no topo da atmosfera, banda a banda, no cálculo do EVI para seis diferentes alvos do bioma Cerrado. Os autores relataram não haver diferença significativa entre o EVI calculado com e sem correção atmosférica. Saini et al. (2016) compararam dados multiespectrais após aplicação dos modelos FLAASH e QUAC, com dados TOA e verificaram que o FLAASH produziu uma reflectância mais realista, especialmente em áreas nubladas.

Silva et al. (2008), por sua vez, ao compararem dados com e sem correção atmosférica em áreas do Ceará (estado que abrange 100% do bioma Caatinga) constataram haver diferença significativa entre os dados, banda a banda. Bezerra et al. (2011) ao desenvolverem estudo similar, também em área abrangida pela Caatinga, obtiveram nível de significância de 0,01 ao comparar dados com e sem correção atmosférica. Os autores relataram ainda diminuição do albedo de superfície e aumento do NDVI após a correção atmosférica.

Baptista et al. (2001) destacaram que o FLAASH corrige os efeitos da atmosfera compensando a geometria de iluminação solar, a visada do sensor, as variações sazonais e latitudinais da atmosfera, a absorção dos gases da atmosfera e o espalhamento molecular e por aerossóis. Considerando a forte influência da sazonalidade na Caatinga, este método pode se mostrar altamente potencial para classificar a cobertura do solo do bioma, especialmente contabilizando o fato de o mosaico temporal incluir inevitavelmente informações de um período mais seco.

3 MATERIAL E MÉTODOS

3.1 Procedimentos Metodológicos

O projeto MapBiomias utiliza imagens Landsat (5, 7 e 8) para mapear e quantificar mudanças na cobertura do solo dos biomas brasileiros. O processamento das imagens Landsat é conduzido na plataforma *Google Earth Engine*, baseada em nuvens de computadores. Esta ferramenta é a base para todos os processamentos desenvolvidos para cada bioma, muito embora cada um possua procedimentos específicos que variam desde a seleção e avaliação dos dados mais adequados a serem processados até o método estatístico que se mostra mais apropriado para diagnosticar a mudança da cobertura do solo ao longo do tempo e do espaço. Com isso, é possível não somente verificar fatores como o grau de preservação da vegetação nativa, o padrão de urbanização e o nível de degradação ambiental para cada bioma, como também investigar os principais motivos que podem estar associados a esses e outros fatores observados.

O objetivo inicial dos primeiros trabalhos desenvolvidos pelo MapBiomias foi basicamente diferenciar áreas vegetadas de áreas não vegetadas a fim de identificar o grau de cobertura vegetal presente nos biomas brasileiros. Essa etapa é também referida como Coleção 1. A Coleção 2, definida em 2016 e já incorporada por este trabalho busca aumentar o número de classes, para melhor especificar as áreas vegetadas e não vegetadas. A metodologia utilizada pelo MapBiomias serviu como subsídio para o desenvolvimento deste trabalho. Essa metodologia sofreu algumas modificações a fim de se adequar ao objetivo proposto, conforme apresentado pela Figura 8.

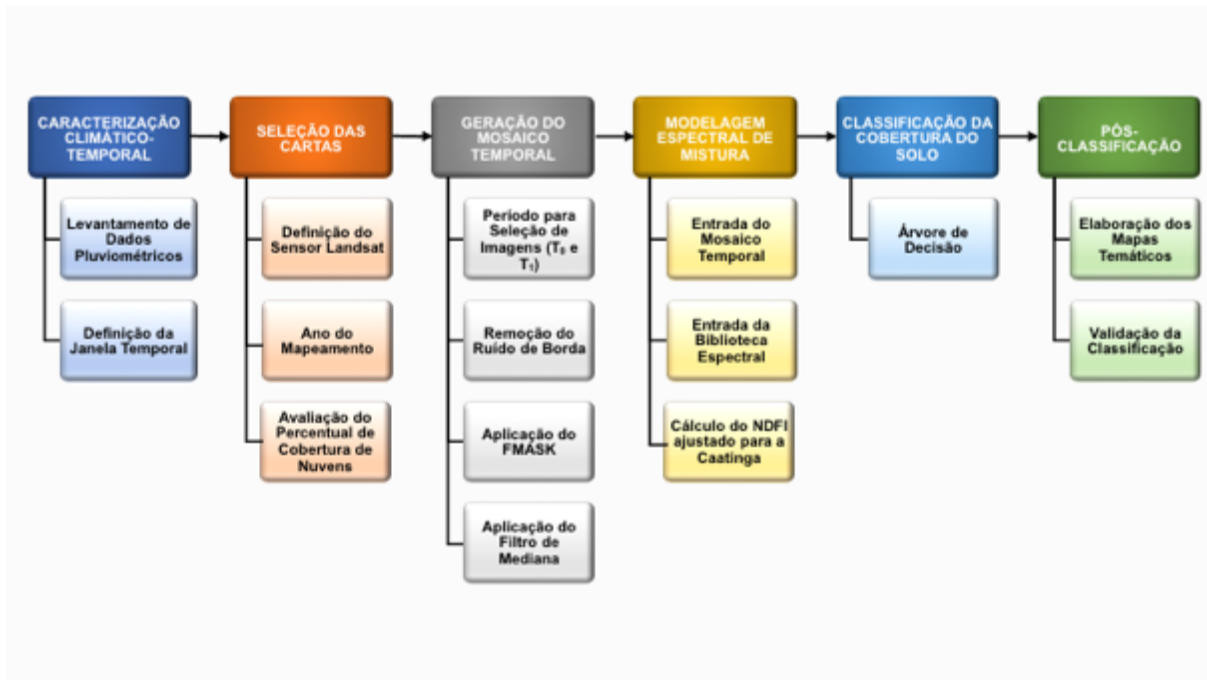


Figura 8 - Fluxograma Metodológico do MapBiomias adaptado para o presente estudo

Primeiramente, foi feita uma caracterização climático-temporal dos dados. Essa etapa caracteriza-se basicamente pela coleta de dados pluviométricos, as quais serviram como embasamento para definição da melhor janela temporal utilizada para cada carta, tendo em vista o fato de a sazonalidade ser um dos fatores de maior impacto na classificação da cobertura do solo na Caatinga. Além disso, essa etapa é pré-requisito necessário para a seleção das cartas, uma vez que o intervalo temporal é necessário para uma seleção mais apurada das cartas a serem avaliadas neste trabalho. Com isso as 68 cartas que cobrem o bioma foram analisadas em termos da qualidade dos mosaicos. Devido ao intervalo temporal de análise (2013-2016), imagens do sensor OLI (Landsat-8) foram definidas para este estudo.

As etapas de Geração do Mosaico Temporal, Modelagem Espectral de Mistura e Classificação da Cobertura do Solo foram todas desenvolvidas pelo *Code Editor* do GEE a partir de *scripts* pré-definidos, os quais detêm todas as informações espectrais e parâmetros específicos para gerar o dado adequado para cada carta selecionada, em seu ano correspondente. Esses *scripts* são mostrados nos Apêndices 1 e 2, com o primeiro apresentando o *script* para obtenção do dado Landsat em número digital e o segundo o *script* para gerar o dado classificado, o qual descreve todas as etapas e parâmetros utilizados. A incorporação do passo a

passo desenvolvido para proceder com a correção atmosférica nos dados consta no fluxograma da Figura 9 e ocorre após a geração do mosaico temporal, o qual, após ser submetido à correção atmosférica dos dados por meio do *software* ENVI 5.1, mais especificamente em seus módulos FLAASH e QUAC, é reinserido no *Code Editor* do GEE para o processo de classificação. Ao final a etapa de pós-classificação foi desenvolvida por meio do *software* ArcGIS 10.1, tanto para a produção dos mapas temáticos, como para a extração dos dados que subsidiaram as análises estatísticas. Além disso, apesar da etapa de seleção dos mosaicos não ter sido realizada de maneira direta pelo GEE, a ferramenta serviu como base para a avaliação visual das imagens correspondentes a cada carta, então por isso no fluxograma abaixo consta como sendo uma etapa realizada pelo GEE.

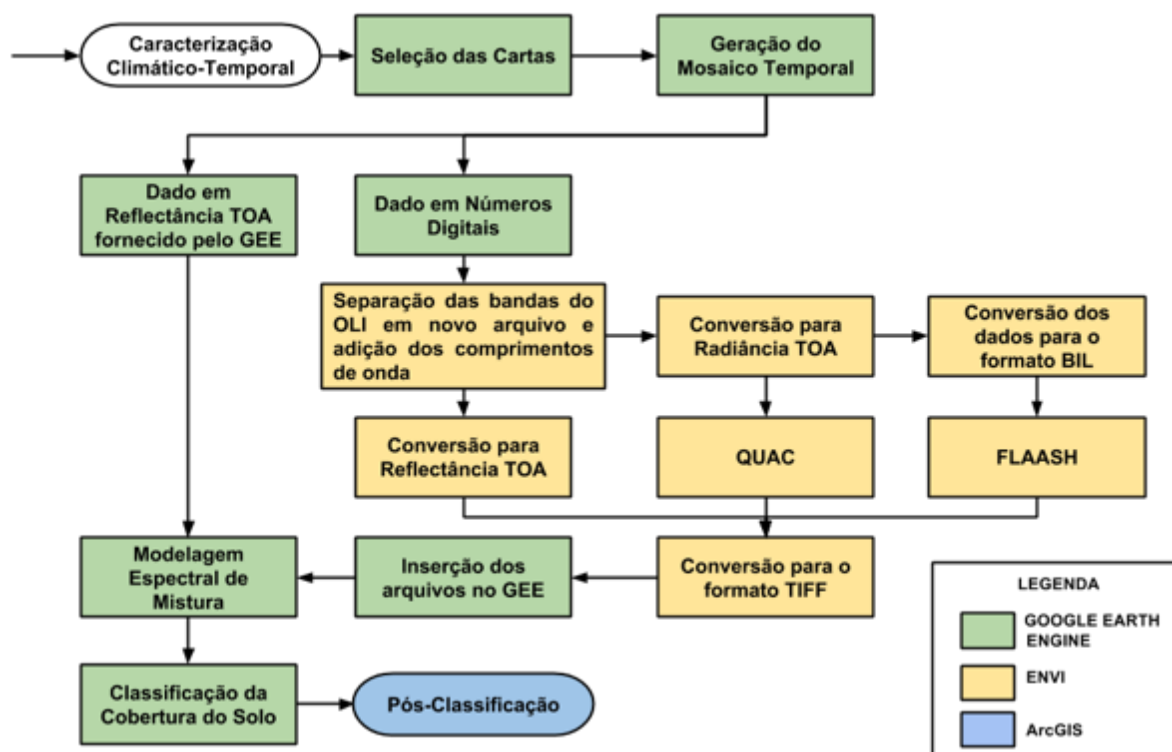


Figura 9 - Fluxograma detalhando os processamentos realizados para a correção atmosférica dos dados, seu papel dentro da metodologia do MapBiomias e as ferramentas utilizadas para produzir cada dado.

A unidade de mapeamento do MapBiomias é a Carta Internacional do Mundo ao Milionésimo na escala 1:250.000, cobrindo uma área de 1°30' de longitude por 1° de latitude. Como o próprio nome sugere tratam-se de cartas de todas as regiões do globo terrestre e a sua utilização, de acordo com Nozawa (1987) se restringe a trabalhos que envolvem grandes áreas. Cada carta possui uma codificação única

discriminando-a. Um total de 558 cartas (ou folhas) cobre o território nacional (Figura 10). Os dados de referência utilizados para avaliar os resultados baseiam-se nos mapas do PROBIO – Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira – divulgado pela Secretaria de Biodiversidade e Florestas do MMA em parceria com uma série de órgãos, dentre os quais se destacam o IBGE e a Universidade Estadual de Feira de Santana (UEFS).

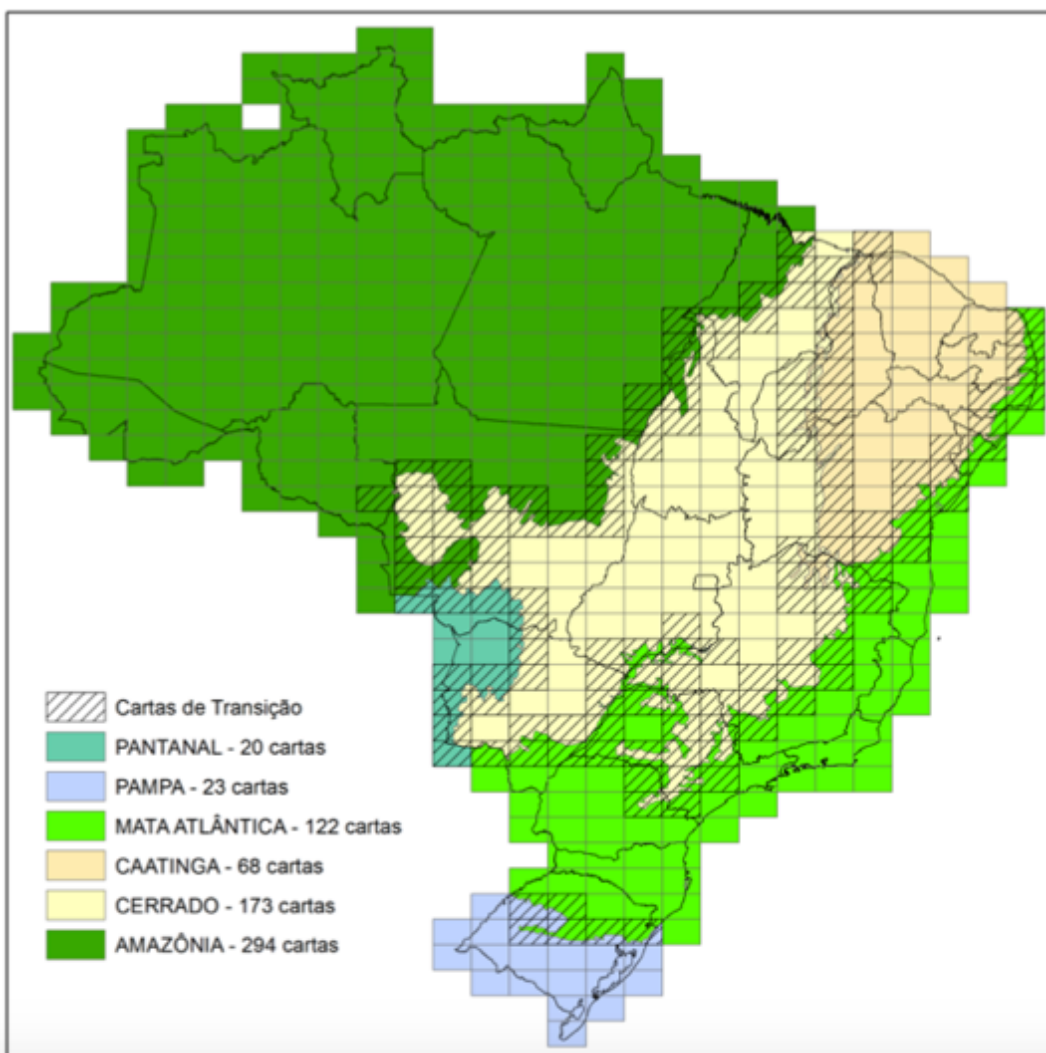


Figura 10 - Distribuição das cartas na escala de 1:250.000 por Bioma
Fonte: MapBiomias, 2015

A Figura 11 apresenta a representação das cartas internacionais do mundo ao milionésimo que encobrem o bioma Caatinga, as quais foram avaliadas com base em parâmetros específicos para posterior seleção daquelas que se mostraram mais adequadas para desenvolver o presente estudo. Apenas para um melhor esclarecimento e para a compreensão do código de cada carta a letra S indica que

as cartas estão localizadas ao sul do Equador. As letras, que para o caso da figura específica que variam de “A até E”, se associam a um intervalo de 4° de latitude se desenvolvendo a Norte e a Sul do Equador e que indicam a latitude limite da folha. A carta “SA” varia de 0 a 4°; “SB”, de 4° a 8°; “SC”, de 8° a 12°; “SD”, 12° a 16°, e “SE”, de 16° a 18°S. Os números, por sua vez, indicam cada fuso que contém a carta. Por fim, as duas últimas letras representam o código da carta para uma escala 1:500.000 e, finalmente, 1:250.000, que é o caso específico.

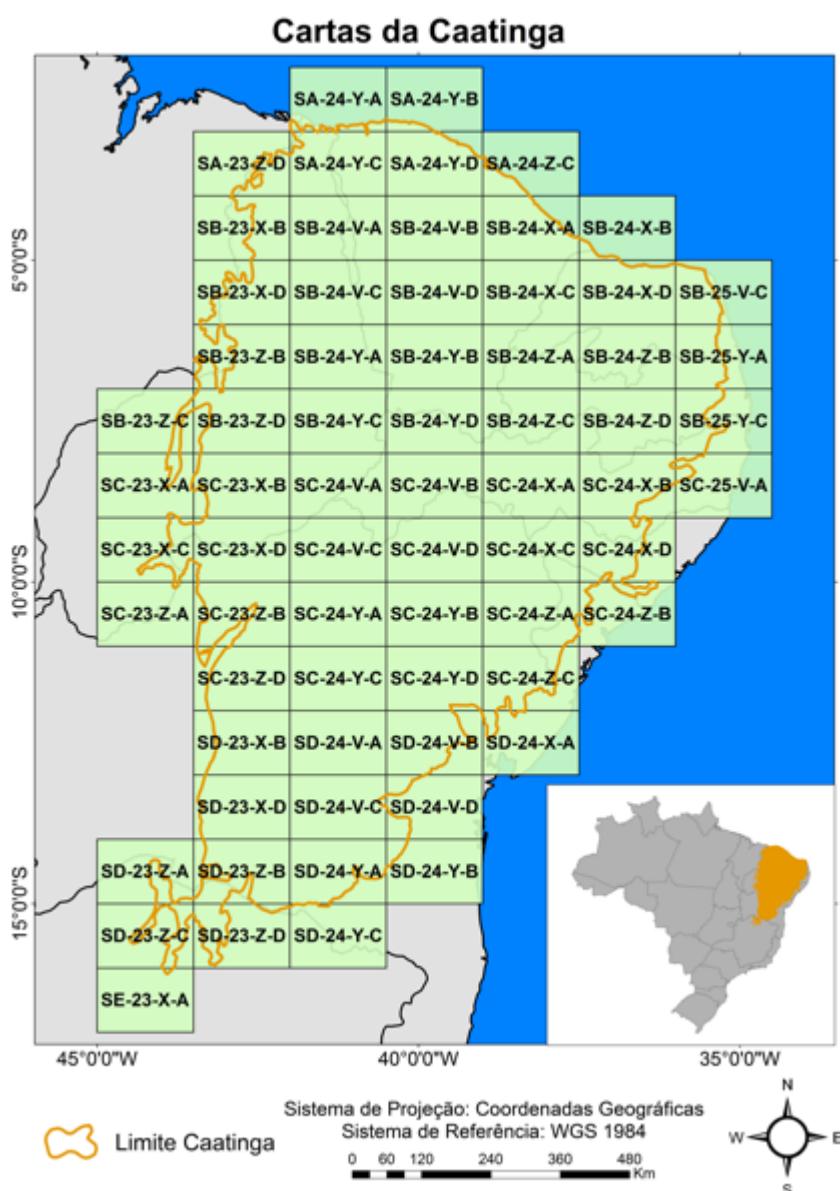


Figura 11 - Mapa com as cartas internacionais do mundo ao milionésimo na escala de 1:250.000 que encobrem a Caatinga.

3.2 Caracterização Climático-Temporal da Área de Mapeamento

Essa etapa de caracterização climático-temporal se deu basicamente pela avaliação dos períodos de chuva do bioma a fim de estabelecer a melhor janela temporal para a construção dos mosaicos, uma vez que é altamente recomendável excluir a época seca a fim de evitar a similaridade espectral entre os alvos. Para isso foi feita uma avaliação prévia da média mensal dos dados fornecidos pelas estações pluviométricas inseridas nos limites do bioma a fim de identificar os melhores meses para compor o mosaico temporal de cada ano avaliado, garantindo uma boa representatividade anual. A Figura 12 apresenta o mapa com a distribuição das estações meteorológicas na Caatinga.




Figura 12 - Mapa das estações meteorológicas na Caatinga

A avaliação dos dados, feita inclusive pela equipe do MapBiomias Caatinga, permitiu verificar que, baseado nos dados já mencionados a janela temporal que

apresentou melhor ajuste foi de 6 meses, sendo, de modo geral, as mais adequadas compreendendo, em ordem de prioridade, os meses de janeiro a junho; fevereiro a julho, e, em última instância, março a agosto. Os meses de julho e agosto geralmente tendem a contribuir para características mais secas na imagem, especialmente ao compor o mosaico temporal por meio do filtro de mediana, onde *pixels* de nuvens, que geralmente ocorrem em abundância na época chuvosa, acabam sendo substituídos pelos *pixels* com informações dos alvos compreendendo a estação seca, que costumam apresentar menor presença de nuvens. Assim, em casos extremos a janela temporal foi reduzida para evitar grande influência da seca.

3.3 Seleção das Cartas

Como o sensor a ser avaliado é o Landsat-8, logo os anos a serem avaliados são: 2013 a 2016. O período a ser preenchido para a geração do mosaico temporal envolve a janela temporal definida na subseção anterior, de modo a garantir o maior contraste espectral possível entre as classes avaliadas. Por fim, foi feita uma avaliação da qualidade dos mosaicos, critério que pode ser considerado o decisivo para a definição das cartas a serem processadas, classificadas e avaliadas neste trabalho.

A avaliação da qualidade dos mosaicos, após definição da janela temporal mais apropriada para garantir a representatividade dos dados, foi procedida majoritariamente com base na verificação do percentual de nuvens. Além disso, e outras interferências que possam ter provocado dificuldade na visualização dos alvos, como ruídos provocados pelo próprio imageamento do sensor. Assim, foi feita uma análise da qualidade dos mosaicos buscando enquadrá-los em três diferentes categorias, com base no percentual de nuvens: boa (<10%), regular (entre 10 e 20%) e ruim (> 30%). A Figura 13 apresenta a avaliação da qualidade dos mapas dos anos imageados pelo Landsat-8.

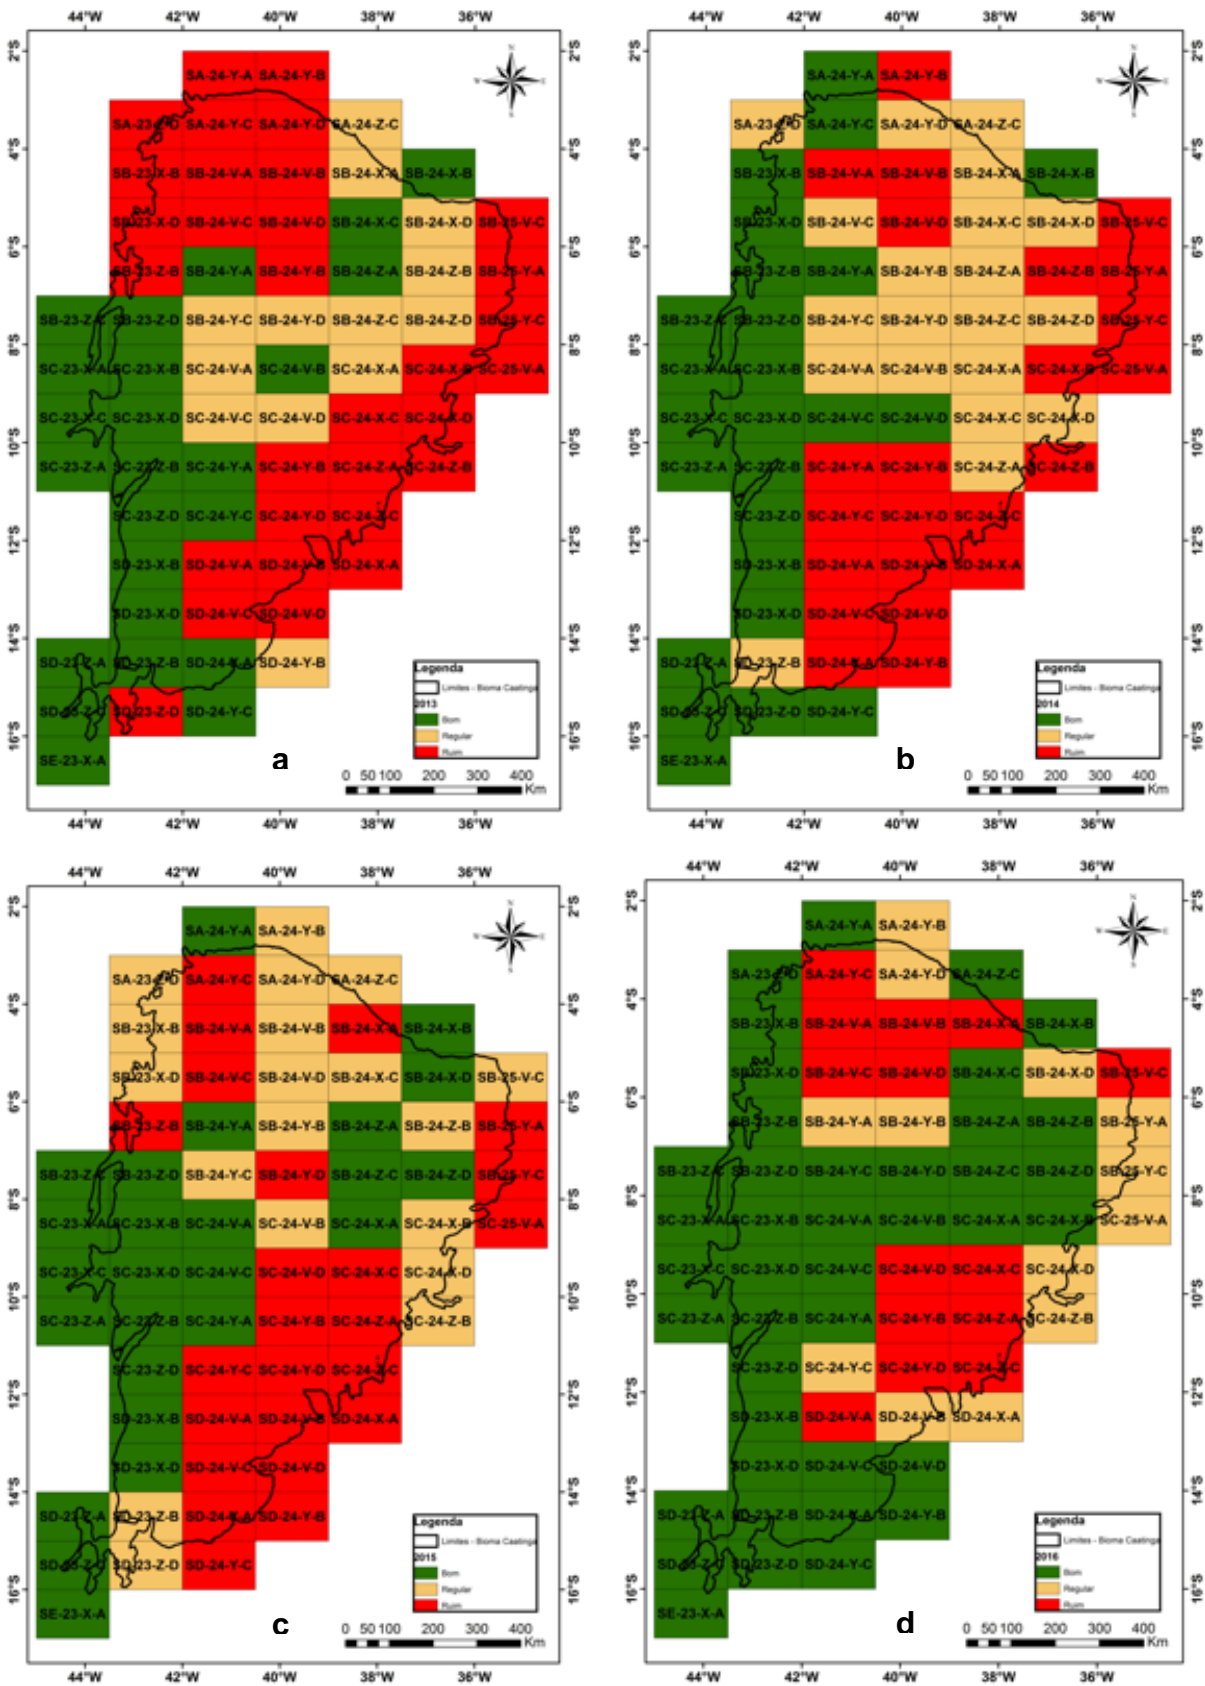


Figura 13 - Mapas de 2013 (a), 2014 (b), 2015 (c) e 2016 (d) com a avaliação dos mosaicos do bioma Caatinga.

O critério para a seleção das cartas, então, partiu-se da seguinte premissa: primeiramente foram descartadas as cartas que foram avaliadas como ruins em pelo menos um dos anos. Em segundo, o descarte das cartas que apresentaram qualidade regular em pelo menos dois anos. Isso quer dizer que foram priorizadas as cartas que apresentaram qualidade boa em todos os anos, ou pelo menos um ano regular. Dentre essas cartas, a prioridade é que estivessem em maior parte inseridas nos limites da Caatinga. Assim, fazendo uma análise comparativa, é possível perceber que praticamente todas as cartas que apresentaram qualidade boa ao longo dos quatro anos se encontram em áreas de transição, tendo maior parte de seu território fora dos limites da Caatinga. Isso levou à consideração de duas cartas para serem submetidas à classificação da cobertura do solo e posterior avaliação estatística: as cartas SC-24-V-C (Petrolina) e SD-23-X-D (Bom Jesus da Lapa). A primeira está 100% inserida no contexto da Caatinga, a segunda, apresenta apenas cerca de 10% em área de transição com o Cerrado, o que ainda garante elevada representatividade para o bioma avaliado.

3.3.1 CARTA SC-24-V-C

A carta SC-24-V-C está compreendida entre os paralelos 9º e 10º de latitude sul e os meridianos 40º30'e 42º de longitude oeste, ocupando uma área de aproximadamente 18.000 km². Localiza-se na região Nordeste do Brasil, região do médio São Francisco, com a maior parte da área situada no norte do estado da Bahia, incluindo pequenas partes do oeste de Pernambuco e sudeste do Piauí. Abrange, total ou parcialmente, os municípios baianos de Remanso, Casa Nova, Sento Sé, Sobradinho, Juazeiro e Campo Formoso, parte do município de Petrolina – PE e parte do município de Dom Inocêncio – PI.

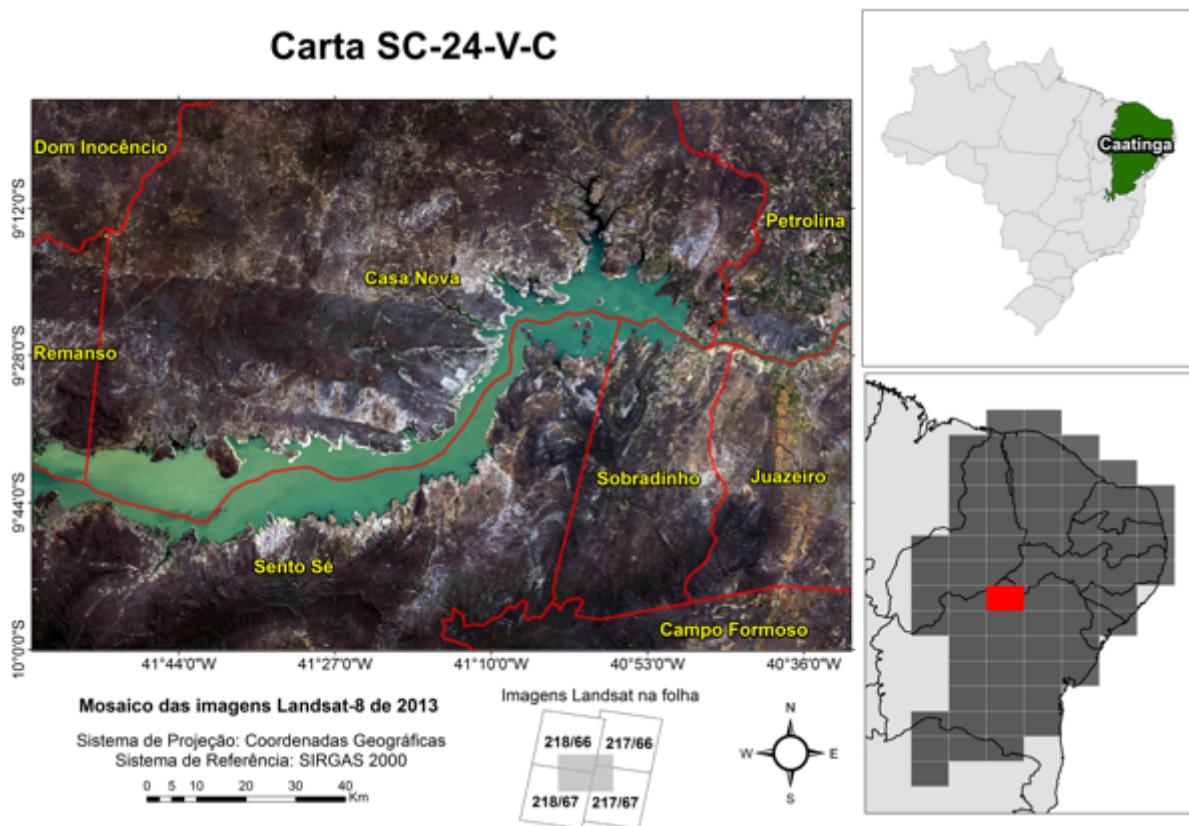


Figura 14 - Mosaico de imagens Landsat-8 da Carta SC-24-V-C para o ano de 2013.

As cidades de Petrolina/Juazeiro, localizadas em margens opostas do rio São Francisco, no extremo centro-oeste da área, constituem o principal polo comercial da região, a partir do qual se irradia uma rede rodoviária que dá acesso às cidades estabelecidas dentro da carta e em suas adjacências. As cidades de Petrolina/Juazeiro distanciam-se de Salvador por 520 km e Recife por 780 km.

Segundo a classificação de Köppen, o clima da região é do tipo semiárido quente, com chuvas de verão (Bshw). Tem por característica a alternância de duas estações definidas: a de chuva, denominada de inverno pelo sertanejo, e a seca ou verão. De acordo com Angelim (1997), as precipitações pluviométricas na região abrangida pela carta são irregulares e geralmente insuficientes (400 a 500 mm anuais, com raros picos de 600 mm); a umidade é baixa e a temperatura elevada (médias anuais variando de 23°C a 30°C, com raros picos menores ou maiores que esse intervalo).

A quase totalidade da área investigada está inserida na bacia hidrográfica do médio São Francisco. O lago de Sobradinho, cuja barragem se encontra a cerca de 50 km a montante das cidades de Juazeiro e Petrolina recobre, a partir daí até o

limite ocidental da carta, todo o curso do rio São Francisco e os baixos cursos dos seus afluentes. Os afluentes do rio São Francisco, dentro do perímetro da carta, são intermitentes, à exceção do rio Salitre que desemboca a jusante da barragem, pela margem direita do curso d'água principal (ANGELIM, 1997).

Observando o mapa de referência da vegetação produzido pelo MMA em parceria com diversos órgãos (Figura 15), a carta caracteriza-se por apresentar as seguintes formações vegetais, cuja nomenclatura referente às classes de vegetação está de acordo com o Manual Técnico da Vegetação do IBGE (2006): Savana Arborizada (Sa); Savana-Estépica Florestada (Td), Savana-Estépica Arborizada (Ta) e Savana-Estépica Parque (Tp); Formação pioneira com influência fluvial e/ou lacustre (Pa); áreas com interferência antrópica (agropecuária (Ag), influência urbana (lu) e áreas degradadas por mineração); corpos d'água e dunas (Dun). Há também áreas de tensão ecológica, representadas por áreas de savana-estépica e floresta estacional (TN) e áreas caracterizadas como refúgio montano (Rm).

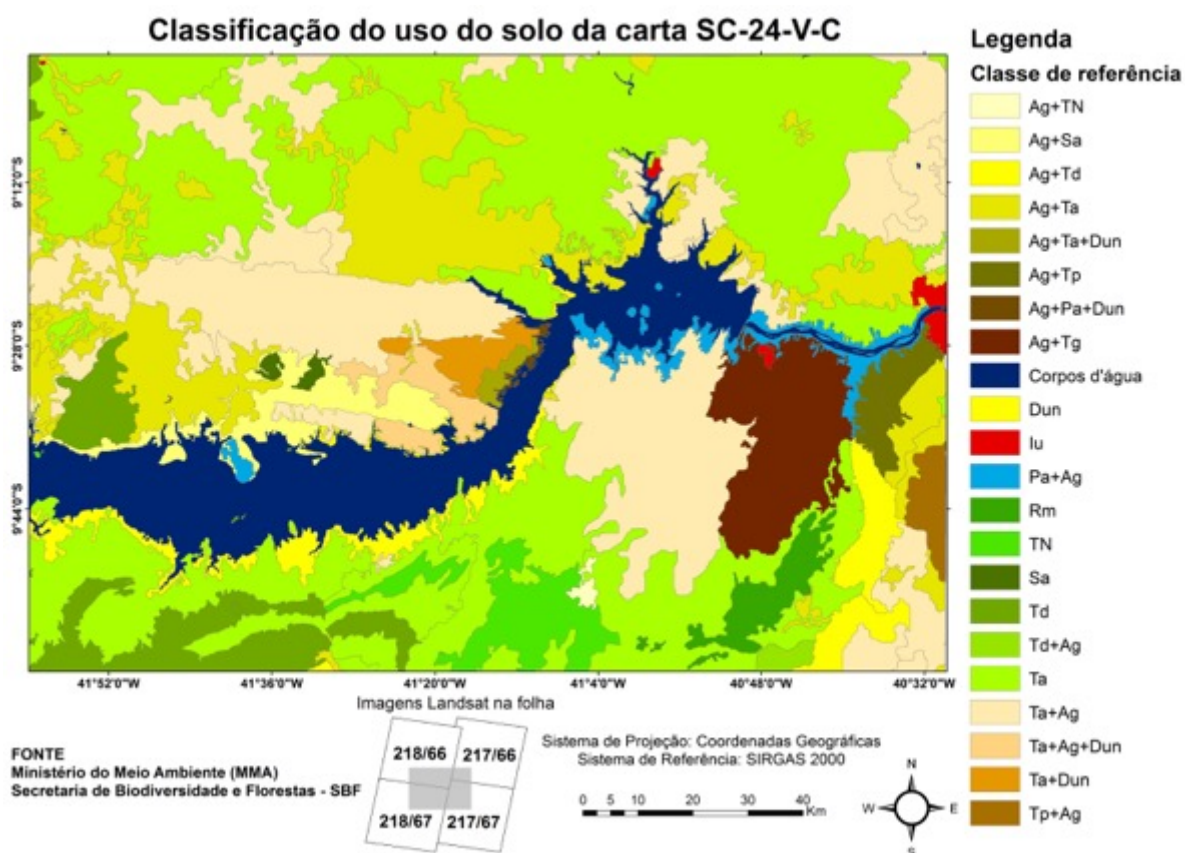


Figura 15 - Mapa de Referência da vegetação a carta SC-24-V-C.
Fonte: Adaptado de Ministério do Meio Ambiente (2006)

3.3.2 CARTA SD-23-X-D

A carta SD-23-X-D cujo principal município é Bom Jesus da Lapa está limitada pelas coordenadas 42°00' a 43°30' de longitude e 13° a 14° de latitude sul e está localizada na região sudoeste da Bahia, totalizando uma área de cerca de 18 mil km². As cartas que recobrem mais de um bioma, ou seja, as cartas de transição, sob a ótica do processamento das imagens, são feitas separadamente, com os parâmetros dos seus respectivos biomas, para em seguida serem combinadas na etapa de pós-classificação. Esta carta específica se trata de uma carta de transição, entretanto abrange uma pequena porção do bioma Cerrado, o qual está situado na porção superior, mais precisamente no lado esquerdo das margens do rio São Francisco. Entretanto, como os parâmetros desse trabalho foram adaptados para o bioma Caatinga e levando-se em consideração que há apenas uma pequena porção de outro bioma na área da carta, não houve classificação da cobertura do solo no âmbito do Cerrado.

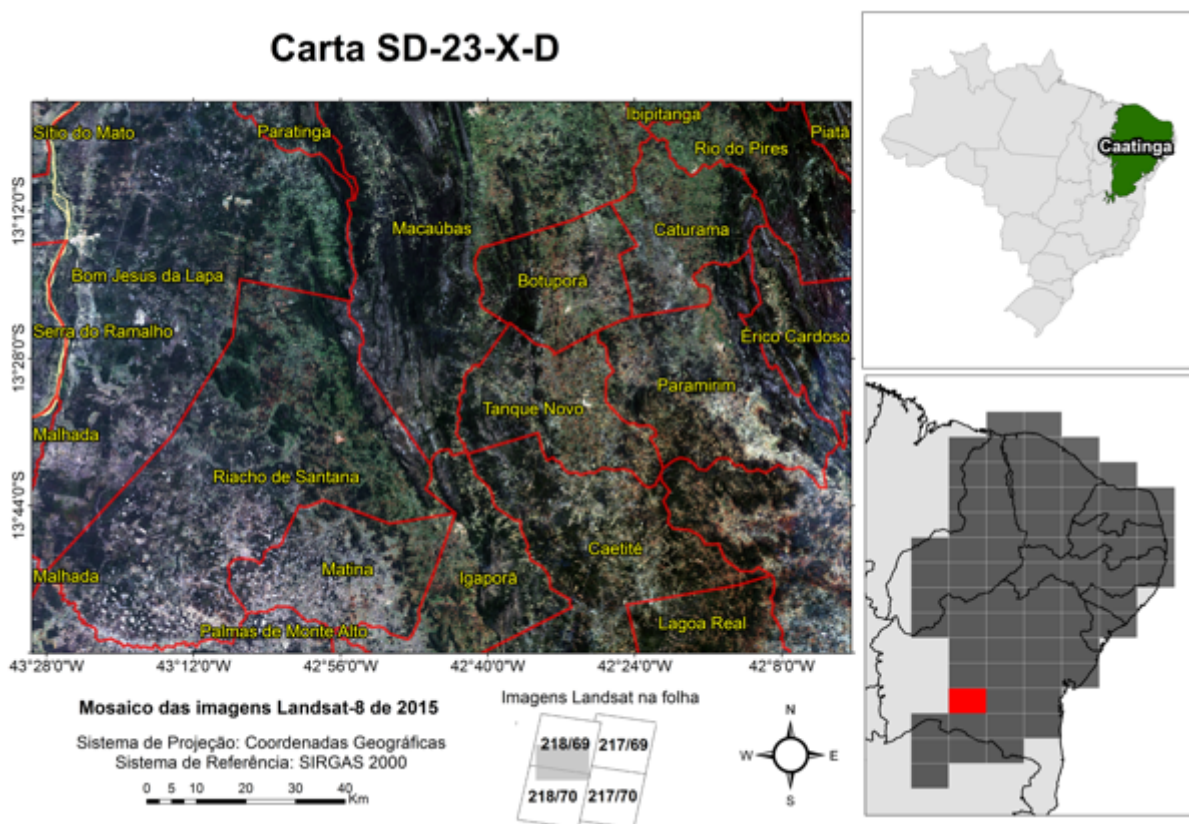


Figura 16 - Mosaico Temporal de imagens Landsat-8 da Carta SD-23-X-D para o ano de 2015.

Ao se observar o mapa de referência da vegetação produzido pelo MMA em parceria com diversos órgãos (Figura 17), a carta caracteriza-se por apresentar as seguintes formações vegetais, cuja nomenclatura referente às classes de vegetação está de acordo com o Manual Técnico da Vegetação do IBGE (2006): Áreas de Tensão Ecológica, caracterizadas por savana estépica/floresta estacional (TN); savana/savana estépica (ST); e savana/savana estépica/floresta estacional (STN) Corpos d'água, Floresta Estacional Semidecidual Submontana (Fs); Floresta Estacional Decidual Montana (Ca) e Submontana (Cm); Savana Arborizada (Sa); Savana Estépica-Arborizada (Ta); Formação pioneira com influência fluvial e/ou lacustre (Pa); Vegetação secundária (Vs), agropecuária (Ag) e influência urbana (Iu).

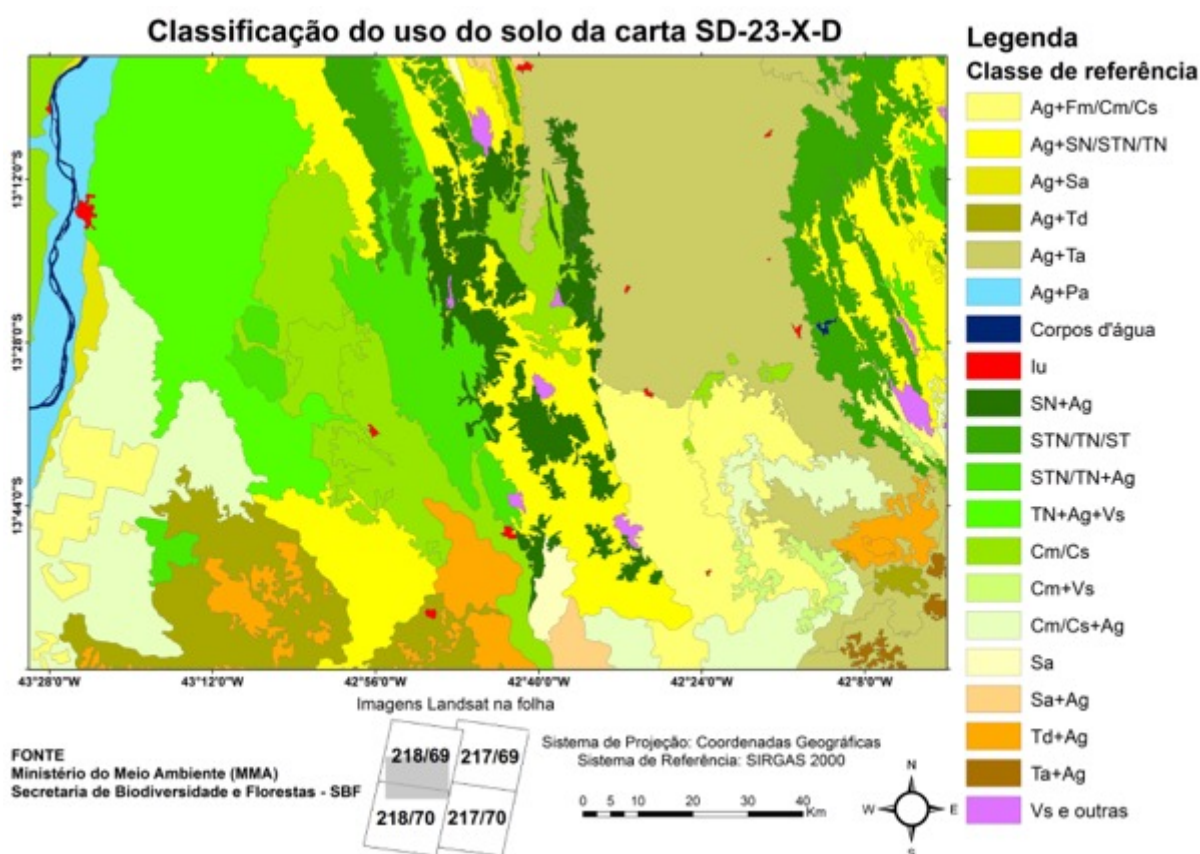


Figura 17 - Mapa de Referência da vegetação a carta SD-23-X-D.

Fonte: Adaptado de Ministério do Meio Ambiente (2006)

3.4 Geração do Mosaico Temporal

A aplicação dos parâmetros descritos acima (período e cobertura de nuvens) permite obter um conjunto de cenas de imagens Landsat para um dado ano, no

período definido, cobrindo a área da carta selecionada para o processamento. Esse conjunto de cenas Landsat é processado com o objetivo de gerar um mosaico temporal com a menor cobertura de nuvens para a carta, otimizando o período de maior contraste espectral das classes de cobertura do solo que serão mapeadas. A Tabela 5 apresenta os parâmetros preenchidos no GEE para a geração do mosaico temporal para cada carta, por ano mapeado.

Tabela 5 - Parâmetros considerados para a geração do mosaico temporal para cada ano de cada carta

CARTA	JANELA TEMPORAL	COBERTURA MÁXIMA DE NUVENS
SD-23-X-D	01/02/2013 a 31/07/2013	20%
Mosaico composto pelos pontos/órbitas: 218/69 – 218/70	01/02/2014 a 31/07/2014	15%
	01/01/2015 a 30/05/2015	1%
	01/01/2016 a 30/06/2016	1%
SC-24-V-C	01/01/2013 a 01/07/2013	4%
Mosaico composto pelos pontos/órbitas: 217/66 – 217/67 – 218/66 – 218/67	03/01/2014 a 30/07/2014	12%
	01/01/2015 a 30/06/2015 –	32%
	01/02/2016 a 15/08/2016 –	3%

As cenas Landsat selecionadas são processadas para gerar o mosaico temporal que cobre a área da carta. Inicialmente remove-se a borda da cena da imagem Landsat (buffer de -5.500m) para remoção de eventuais ruídos de borda. São considerados ruídos os *pixels* das cenas Landsat que não possuem dados em todas as bandas. O próximo passo é aplicar um algoritmo de detecção e remoção de nuvens, o algoritmo *Function of Mask* (FMASK), proposto por Zhu e Woodcock (2012).

O algoritmo FMASK trata-se de um método para detecção de nuvens e as sombras provocadas pelas mesmas em imagens Landsat (ZHU e WOODCOCK, 2012). O produto gerado requer como *inputs* dados em reflectância no topo da atmosfera e temperatura de brilho. A partir de critérios baseados nas propriedades físicas das nuvens o algoritmo separa *pixels* considerados como nuvens potenciais

de *pixels* de céu claro. Em seguida, por meio da combinação das probabilidades dos parâmetros temperatura, variabilidade espectral e brilho dos alvos, é produzida uma máscara para nuvens sobre superfícies terrestres e aquáticas separadamente. Posteriormente, os *pixels* considerados como nuvens potenciais juntamente com a máscara criada são utilizados para derivar uma provável camada de nuvens. Zhu e Woodcock (2012) ainda destacam que o efeito de sombreamento gerado pelas nuvens na região do infravermelho é usado para gerar uma camada de sombra potencial, a qual serve como base para a geração dos alvos de nuvem. Além disso, informações como o ângulo de visada do satélite e a iluminação são usadas como forma de prever possíveis sombras nos locais onde as nuvens são detectadas. Os valores da máscara criada pelo algoritmo são: (0 – céu claro; 1 – água; 2 – sombra; 3 – neve; 4 – nuvem; e 255 – não identificado).

Após a aplicação do FMASK, os *pixels* marcados como nuvem são utilizados como máscara e apagados da imagem original. Por fim, um filtro de mediana é aplicado para os *pixels* não cobertos por nuvens nas imagens, para compor a imagem final da carta, denominada de mosaico temporal.

O efeito do filtro da mediana é o de remover ruído e de suavizar a imagem. Por descartar os valores extremos em cada vizinhança, a mediana remove ruído de maneira mais eficiente que a média. O filtro da mediana também é superior ao filtro da média com relação às bordas presentes nas imagens. Enquanto a mediana preserva as transições rápidas, a média, por considerar os valores da janela no cálculo do valor final de cada *pixel*, atenua estas transições. A janela temporal de no máximo 6 meses buscou ser mantida para reduzir mudanças significativas na cobertura florestal e aumentar a área da superfície observada a partir do processo de filtragem de nuvens descrito acima (Figura 18).



Figura 18 - Comparação entre uma imagem e um mosaico temporal após aplicação do filtro de mediana. Fonte: MapBiomass, 2015

3.5 Etapa de Processamento no ENVI (Correção Atmosférica)

3.5.1 Conversão dos dados brutos para Radiância e Reflectância TOA

A série Landsat tem operado por quase 40 anos e a conversão dos seus dados para radiância e reflectância TOA foi relatada em diversos artigos, com destaque para Markham e Barker (1986), Chander e Markham (2003) e Chander et al. (2009). Essas conversões para o Landsat-8 seguem os moldes das equações propostas para as versões anteriores do Landsat, com diferenças muito sutis (MISHRA et al., 2014). Os produtos L1T são distribuídos pelo USGS EROS em formato inteiro de 16 bits sem assinatura e podem ser convertidos para radiância e reflectância por meio dos coeficientes de reescalonamento fornecidos pelo arquivo de metadados (MTL) do produto (USGS, 2012).

3.5.2 Conversão para Radiância TOA

O cálculo da radiância espectral no nível do sensor (TOA) caracteriza-se como uma etapa fundamental na conversão de dados de diversos sensores para uma escala radiométrica comum significativa em termos físicos. De acordo com Chander et al. (2009), a calibração radiométrica dos sensores da série Landsat

envolve o reescalonamento dos números digitais brutos (Q) transmitidos pelo satélite para números digitais calibrados (Q_{cal}), os quais possuem a mesma escala radiométrica para todas as cenas processadas na superfície terrestre em um dado período.

Ainda de acordo com os autores, durante a calibração radiométrica, os valores dos *pixels* das imagens brutas (Q) são convertidos para unidades de radiância espectral absoluta usando cálculos de ponto flutuante de 32 bits. Os valores de radiância absoluta são, enfim, escalonados para números de 16 bits ($Q_{calmax}=65535$) representando Q_{cal} antes da saída para os meios de distribuição. A conversão do Q_{cal} nos produtos L1T para a radiância no nível do sensor requer conhecimento prévio dos limites superiores e inferiores dos fatores de reescalonamento originais.

A conversão dos dados de números digitais para radiância TOA foi proposta inicialmente por Markham e Baker (1986) por meio da Equação 14 para os sistemas sensores MSS e TM do Landsat, sendo posteriormente revisada por Chander et al. (2007; 2009) tanto para o sensor TM quanto para o ETM+, por meio da Equação 15.

$$L_{\lambda} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) (Q_{cal} - Q_{calmin}) + LMIN_{\lambda} \quad (14)$$

$$L_{\lambda} = G_{rescale} \times Q_{cal} + B_{rescale} \quad (15)$$

Em que: L_{λ} é a radiância espectral aparente ($W \ m^{-2} \ sr^{-1} \ \mu m^{-1}$); Q_{cal} é o valor quantizado e calibrado do *pixel*, ou seja, o número digital a ser convertido; Q_{calmin} é o valor mínimo quantizado e calibrado do *pixel* correspondente a $LMIN_{\lambda}$; Q_{calmax} é o valor máximo quantizado e calibrado do *pixel* correspondente a $LMAX_{\lambda}$ (ND); $LMIN_{\lambda}$ é a radiância espectral máxima no nível do sensor que é escalonada para Q_{calmin} ($W \ m^{-2} \ sr^{-1} \ \mu m^{-1}$); $LMAX_{\lambda}$ é a radiância espectral mínima no nível do sensor que é escalonada para Q_{calmax} ($W \ m^{-2} \ sr^{-1} \ \mu m^{-1}$); $G_{rescale}$ é o fator de ganho específico da banda; e $B_{rescale}$ é o fator aditivo específico da banda.

As Equações 16 e 17 explicam as variáveis $G_{rescale}$ e $B_{rescale}$. Para o sensor OLI, do Landsat-8, Mishra et al. (2014) consideraram diferenças bastante sutis no cálculo de ambas as variáveis. Basicamente, o valor mínimo quantizado e calibrado (Q_{calmin}) passou a ser considerado 1, e não zero como nas versões anteriores do

Landsat. Além disso, as variáveis G_{rescale} e B_{rescale} passaram a ser referidas como M_L e A_L , para fatores de reescalonamento multiplicativo e aditivo, respectivamente, e seus valores específicos para cada banda passaram a constar no arquivo de metadados (MTL) das cenas.

$$G_{\text{rescale}} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{\text{calmax}} - Q_{\text{calmin}}} \right) \quad (16)$$

$$B_{\text{rescale}} = LMIN_{\lambda} - \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{\text{calmax}} - Q_{\text{calmin}}} \right) Q_{\text{calmin}} \quad (17)$$

No caso da conversão para radiância, cada cena possui valores específicos para ambos os fatores multiplicativo e aditivo. Porém, como os mosaicos processados neste trabalho são um produto da mediana dos *pixels* de cada cena abrangida pelo intervalo temporal pré-determinado, logo tem-se um conjunto de informações de todas essas cenas em uma mesma imagem, não sendo possível levar em consideração todos os fatores de reescalonamento na conversão. Ao mesmo tempo, a diferença entre esses valores de uma cena para outra é muito sutil, variando a partir da quarta casa decimal para os fatores multiplicativos e em menos de uma unidade para os fatores aditivos. Isso permitiu que fossem utilizados os mesmos fatores de reescalonamento para proceder com a conversão dos dados para as imagens processadas neste trabalho, conforme apresentado na Tabela 6.

Tabela 6 - valores utilizados para conversão dos dados de números digitais para radiância no topo da atmosfera

	Fator Multiplicativo (M_L)	Fator Aditivo (A_L)
Banda 1	0,012249	-60,78288
Banda 2	0,012544	-62,24241
Banda 3	0,011206	-57,35585
Banda 4	0,0097473	-48,36568
Banda 5	0,0059195	-29,59738
Banda 6	0,0014721	-7,36060
Banda 7	0,00049618	-2,48092
Banda 8	0,010947	-54,73664
Banda 9	0,0023135	-11,56733

3.6 Aplicação do FLAASH

3.6.1 Configuração dos parâmetros de entrada e saída

Para aplicar o FLAASH é necessária a conversão do dado bruto, em número digital, para radiância, uma vez que este é o dado de entrada requerido pelo aplicativo. Todavia, sabe-se que a radiância pode ser quantificada tanto em nível de superfície como no topo da atmosfera. Como o algoritmo FLAASH, ao fazer a correção dos efeitos atmosféricos, converte os dados para reflectância de superfície, espera-se que o dado de entrada (*input*) seja em radiância no topo da atmosfera. A maioria dos estudos que utilizaram o FLAASH para corrigir os efeitos atmosféricos procederam dessa forma (NASCIMENTO e SANO, 2010; PATHAK et al., 2014; CARVALHO e BAPTISTA, 2015; KANTAKUMAR e NEELAMSETTI, 2015; KUMAR e ACHARYA, 2016).

Outra questão que precisa ser levada em consideração para executar o FLAASH é o formato do dado de entrada. Geralmente, após o dado ser convertido para radiância para então ser inserido como *input* no FLAASH, este encontra-se no formato BSQ. Entretanto, o FLAASH requer que o *input* esteja em formato BIP ou BIL. Van Aardt et al. (2010) destacam que o BIP é um formato útil caso o analista esteja buscando informação em locais específicos em arquivos com centenas de bandas presentes, como no caso de dados de sensores hiperespectrais. Considerando a afirmação dos autores e tendo em vista o fato de o presente estudo ter sido desenvolvido utilizando-se dados multiespectrais, o formato BIL mostra-se mais adequado. Além disso, diversos autores ao utilizarem o FLAASH para corrigir os efeitos atmosféricos em dados Landsat utilizaram o formato BIL como *input* (YUAN e NIU, 2008; NASCIMENTO e SANO, 2010; ARIAS et al., 2014; KUMAR e ACHARYA, 2016; XIAO et al., 2016). Contudo, é importante que fique claro que os manuais e artigos disponíveis na literatura que orientam sobre o processamento no FLAASH não fazem qualquer diferenciação quanto à influência que a escolha de um formato em detrimento do outro pode exercer no resultado final.

Após inserir o *input*, caso os comprimentos de onda não sejam definidos previamente no cabeçalho da imagem (*header*), o FLAASH solicita a inserção de um arquivo no formato ASCII contendo os comprimentos de onda e largura a meia altura (FWHM) de cada banda. De acordo com Baptista (2012), a informação contendo a FWHM considera que a função de resposta espectral da banda seja gaussiana e que sua amplitude seria a medida da largura da área abaixo da função determinada na metade da altura da crista da função. Porém, a informação referente à largura a meia altura é obrigatória apenas para sensores hiperespectrais. Neste trabalho optou-se por inserir os dados no cabeçalho da imagem. Porém, é importante salientar que com relação ao comprimento de onda, ambas as formas de inserção do dado apresentadas, devem informar o comprimento de onda central de cada banda. A Tabela 7 apresenta essa informação assim como a largura a meia altura de cada banda do sensor OLI do Landsat-8.

Tabela 7 - Bandas do OLI e os seus respectivos comprimentos de onda central e largura a meia altura. Fonte: USGS (2012)

BANDA	COMPRIMENTO DE ONDA CENTRAL (nm)	LARGURA A MEIA ALTURA – FWHM (nm)
Banda 1 – Coastal Aerosol	442.96	15.98
Banda 2 – Azul	482.04	60.04
Banda 3 – Verde	561.41	57.33
Banda 4 – Vermelho	654.59	37.47
Banda 5 – Infravermelho Próximo	864.67	28.25
Banda 6 – Infravermelho de ondas curtas (SWIR) 1	1608.86	84.72
Banda 7 – Infravermelho de ondas curtas (SWIR) 2	2200.73	186.66
Banda 8 – Pancromática	589.50	172.40
Banda 9 – Cirrus	1373.43	20.39

O dado em radiância deve fornecer dado no formato numérico de ponto flutuante, inteiro estendido de 4-bytes, ou inteiro com assinatura de 2-bytes ou sem assinatura, e geralmente é calculado em watts por metro quadrado por esterradiano por micrômetro ($W m^{-2} sr^{-1} \mu m^{-1}$). Entretanto, o FLAASH requer que o dado de entrada, em radiância, esteja em microwatts por centímetros quadrados por esterradiano por nanômetro ($\mu W cm^{-2} sr^{-1} nm^{-1}$) (ENVI FLAASH, 2005). Dessa forma, para proceder com a conversão é necessário aplicar um fator de escala que permite o ajuste da unidade em radiância do arquivo de entrada no momento do

processamento dentro do FLAASH. A função do fator de escala é de dividir o dado de entrada pelo valor informado de modo a proceder com a conversão das unidades. Assim, foi aplicado um fator de escala 10. É possível chegar nesse valor por meio do produto dos fatores de conversão de cada componente das unidades transformadas separadamente, conforme demonstrado na Tabela 8:

Tabela 8 - Conversão de unidades e seus fatores de escala correspondentes para inserção no FLAASH

Unidade anterior	Unidade convertida	Fator de escala
Watts (W)	Microwatts (μW)	10^6
Metros quadrados (m²)	Centímetros quadrados (cm²)	10^{-4}
Micrômetros (μm)	Nanômetros (nm)	10^{-3}
<u>$10^6 \times 10^{-4} \times 10^{-3} = 10^{-1}$</u>		

Isso mostra que o fator de escala é 10^{-1} ou 1/10. O valor preenchido no campo *Single Scale Factor*, que aparece após a inserção do dado de entrada, deve ser preenchido conforme o valor referente ao denominador da escala, ou seja, 10, e não 0,1, para este caso. Caso o *input* estivesse nas unidades corretas, bastaria preencher o campo com o valor 1.

3.6.2 Parâmetros da Cena e Informações do Sensor

As coordenadas geográficas (latitude e longitude) são preenchidas automaticamente no momento em que o *input* é inserido. Em seguida, deve ser preenchido o campo “tipo do sensor”. No caso deste trabalho trata-se do Landsat-8 OLI, um sensor multiespectral. O campo altitude do sensor é preenchido automaticamente de acordo com o tipo do sensor escolhido. A elevação do terreno foi definida a partir da superposição da imagem no *Google Earth* e da geração do perfil de elevação da cena. Foi feito um perfil no sentido leste/oeste e outro no sentido norte/sul, ambos passando pelo centro da cena. Os valores obtidos como médias de perfil de elevação foram 783 e 727 metros para a carta SD-23-X-D e 618 e 579 metros para a carta SC-24-V-C. Com isso, adotou-se o valor médio entre esses dois valores, ou seja, 755 metros (0,755 km) para a primeira carta e 598

metros (0,598 km) para a segunda. O campo relacionado ao tamanho do *pixel*, por sua vez, foi preenchido com o valor de 30 metros, tamanho dos *pixels* das bandas do OLI.

Os campos relacionados à data e hora do voo demandaram uma atenção especial, uma vez que juntamente com os parâmetros descritos no parágrafo anterior, possibilitam que o FLAASH determine a posição solar e a sua incidência sobre a superfície. Como as cartas obtidas pelo GEE tratam-se de mosaicos formados pela mediana do *pixel* de cada cena que os compõem, em um intervalo temporal pré-determinado, logo não se tem um produto que apresenta uma data e hora de imageamento específicos. Itten e Meyer (1993) constataram que um mesmo objeto exhibe diferentes valores de intensidade diante de variações da posição do sol e topografia. A solução encontrada para contornar essa questão foi a definição de uma data e hora médias para cada carta. Para isso, por meio de uma consulta detalhada na plataforma *Earth Explorer* do USGS aos metadados das cenas que compõem os mosaicos gerados pelo GEE, foi criada uma tabela com a compilação das datas, horas e informações de elevação e azimute para cada data abrangida pelo intervalo temporal de cada carta (Apêndice 3). No campo hora, como no metadado consta a hora inicial e final do imageamento de cada cena, foi considerada a hora inicial, de acordo com *Greenwich*. O imageamento de cada ponto/órbita dura cerca de 30 segundos, ou seja, a escolha da data inicial em detrimento da data final de imageamento não causa qualquer impacto no resultado do FLAASH.

Após o levantamento das informações necessárias foi possível estimar a data e hora mais representativa para executar o FLAASH. Primeiramente, foi calculada a média de elevação e azimute para cada ano de cada ponto/órbita. Isso gerou novas 24 médias. A partir disso, foi calculada uma nova média para cada elevação e azimute considerando o mesmo ano dos pontos e órbitas que englobam cada uma das duas cartas. Com posse das médias finais, foram observadas as datas e horas com maior grau de concordância com esses valores, em conformidade com a Tabela do Apêndice 3 e conforme exposto pela Tabela 9.

Tabela 9 - Informações correspondentes a data, hora, elevação e azimute das cartas utilizadas

CARTA	ANO	ELEVAÇÃO (graus)	AZIMUTE (graus)	DATA	HORA (GMT)
SC-24-V-C	2013	50,89	44,61	14/05/13	12:50:07
	2014	54,26	67,38	30/03/14	12:48:22
	2015	54,73	71,84	24/03/15	12:53:51
	2016	52,80	58,22	11/04/16	12:53:55
SD-23-X-D	2013	46,46	41,20	21/05/13	12:57:10
	2014	50,68	57,16	06/04/14	12:55:16
	2015	51,91	64,95	24/03/15	12:55:03
	2016	52,61	66,41	26/03/16	12:54:50

3.6.3 Seleção dos Parâmetros Atmosféricos

A escolha do modelo atmosférico para os processamentos realizados foi o Tropical, uma vez que a porção da Caatinga presente nas imagens processadas possui temperaturas bastante elevadas ao longo do ano. Além disso, a posição latitudinal do bioma também justifica a escolha do referido modelo para processar o FLAASH, estando a carta SD-23-X-D inserida entre as coordenadas latitudinais 13° e 14°, e a carta SC-24-V-C entre 9° e 10°.

Para a maioria dos sensores multiespectrais, incluindo o Landsat, o campo *Water Retrieval* é automaticamente ajustado para a opção “não”, o que quer dizer que a estimativa da presença de água não é restaurada em cada *pixel*. Quando isso acontece, é atribuído um valor constante para o valor da coluna de vapor d’água em todos os *pixels* da imagem, que deve ser preenchido no campo *Water Column Multiplier*. O valor padrão adotado neste trabalho foi 1, o que se justifica pelo fato de o Landsat não possuir uma banda própria para corrigir o vapor d’água. Alguns estudos procederam da mesma forma ao corrigirem os efeitos atmosféricos com o FLAASH em imagens Landsat (NASCIMENTO e SANO, 2010; MITCHELL et al., 2013; ELS et al., 2015). Além disso, o modelo de aerossol escolhido para ambas as cartas foi o rural, pois não se tratam de áreas fortemente afetadas por áreas urbano-industriais, o que representa um modelo de aerossol composto pela mistura de dois padrões de partícula, uma maior e outra menor. É importante destacar que a

relevância desse parâmetro para o FLAASH se torna maior caso a visibilidade seja menor que 40 km.

Para determinar a quantidade de aerossol, no campo *Aerosol Retrieval* foi selecionada a opção *2-Band (K-T)*, a qual utiliza as bandas 4 (655 nm) e 7 (2200 nm) do sensor OLI do Landsat-8, assim como uma razão quase constante de reflectância entre essas bandas para identificar *pixels* escuros. Ao selecionar esta opção, caso os *pixels* escuros adequados não sejam encontrados para o *input*, o valor preenchido no campo *Initial Visibility*, que se trata da visibilidade inicial, passa a ser considerado. O valor padrão de visibilidade mantido pelo FLAASH é de 40 km. Entretanto, é recomendável que este parâmetro seja estimado a máxima exatidão, uma vez que pode variar de cena para cena.

As propriedades ópticas do aerossol dependem do comprimento de onda da radiação, assim como a profundidade óptica do aerossol. As variações com o comprimento de onda podem ser substanciais, razões pelas quais torna-se importante sempre especificar o comprimento de onda associado a uma dada profundidade óptica do aerossol. O coeficiente de Angstrom, também denominado parâmetro de Angstrom ou expoente de Angstrom, mede a dependência espectral da profundidade óptica do aerossol (ou coeficiente de extinção). A integral do coeficiente de extinção no sentido vertical é denominada espessura óptica do aerossol ou ainda profundidade óptica do aerossol. Muito embora em um sentido mais restrito exista uma distinção entre a espessura e profundidade ópticas do aerossol (a primeira refere-se à integral da superfície para o topo da atmosfera e a segunda representa uma coordenada vertical), em termos práticos o termo profundidade é frequentemente adotado em referência à espessura (BOUCHER, 2015). Ainda assim, de acordo com o manual do FLAASH, apesar de se relacionarem intrinsicamente, a profundidade óptica do aerossol pode ser convertida no coeficiente de extinção, dividindo-o pela camada de espessura óptica efetiva do aerossol, a qual tipicamente apresenta valores em torno de 2 km, mas varia em função de fatores como a visibilidade, grau de elevação, entre outros.

No algoritmo MODTRAN, quando há presença de *pixels* escuros, a visibilidade é estimada a partir da própria imagem e está relacionada com a profundidade horizontal óptica em 550 nm. O comprimento de onda em 550 nm é utilizado na bibliografia para calcular esses parâmetros por corresponder ao pico do espectro solar que atinge o topo da atmosfera (BERGIN, 2000). Visibilidade é

definida por Jimoda (2012) como a maior distância pela qual um observador pode distinguir um objeto do seu plano de fundo. Este parâmetro pode ser determinado a partir da Equação 18 de turbidez de Angstrom (1929) e Equação 19 de visibilidade de Deschamps et al. (1981):

$$\tau_{a(\lambda)} = \beta \cdot \lambda^{-\alpha} \quad (18)$$

$$\beta = 0,613 \cdot e^{-V/15} \quad (19)$$

Em que: $\tau_{a(\lambda)}$ é a profundidade óptica do aerossol (ou coeficiente de extinção); λ é o comprimento de onda, em micrômetros; α é o expoente de Angström, que se refere à distribuição média de tamanho dos aerossóis presentes e cujos valores variam de 0,1 (partículas grandes) a 1,3 (partículas pequenas); β é o coeficiente de turbidez de Angström, que descreve a concentração de aerossol e varia de 0,1 (atmosfera clara) a 0,5 (atmosfera turva); e V é a visibilidade, em km.

Ao isolar β na Equação 18 e V na Equação 19, e substituindo β na Equação 19 é possível obter a Equação 20 para cálculo direto da visibilidade.

$$V = \left| (-15) \ln \left(\frac{\tau_{a(\lambda)} \lambda^\alpha}{0,613} \right) \right| \quad (20)$$

Outra forma de calcular a visibilidade bastante utilizada na literatura é por meio da fórmula de Koschmieder (1924), a qual relaciona a visibilidade com o coeficiente de extinção do ar, conforme apresentado pela Equação 21.

$$V = \frac{3,912}{\tau_{a(\lambda)}} \quad (21)$$

O valor de 3,912 foi definido por Koschmieder, após realizações de alguns cálculos, que considerou um contraste de 0,02, ou seja, valor este levado em conta se for observado um objeto negro contra o horizonte em um limiar de contraste detectável por um observador em condições normais. Além disso, o autor também adotou como suposições fundamentais os seguintes fatos: o caminho de observação

como sendo homogêneo e uniformemente iluminado, o objeto ser grande o bastante e não ocorrer distúrbio no campo luminoso, a distância ser tomada na horizontal e a curvatura da terra ser ignorada.

Com a definição dos parâmetros necessários para obter a visibilidade, foi feita uma consulta à plataforma da AERONET (*Aerosol Robotic Network*), da NASA (www.aeronet.gsfc.nasa.gov/new_web/aerosols.html), para coletar valores de profundidade óptica do aerossol e coeficiente de Angstrom. A AERONET é uma rede mundial de monitoramento de aerossóis, a qual utiliza fotômetros solares multiespectrais em superfície (HOLBEN et al., 1998). Vários equipamentos da rede estão espalhados em localidades diferentes do globo, o que acaba viabilizando a determinação das propriedades ópticas, radiativas e microfísicas do aerossol integradas na coluna atmosférica a partir de medições de radiâncias espectrais, as quais, por sua vez, permitem a caracterização de aerossóis.

Existem 13 fotômetros da rede AERONET instalados em território brasileiro, sendo a maioria presente na região Centro-Sul. Na região Norte há apenas um em Porto Nacional – TO e outro em Tucuruí – PA e na região Nordeste apenas um na cidade de Petrolina – PE, o qual foi escolhido para a aquisição dos dados, pois a carta SC-24-V-C engloba Petrolina, e a cidade é a que apresenta menor distância física dos municípios da carta SD-23-X-D. Além disso, a vantagem de Petrolina em comparação às demais cidades que abrigam fotômetros está associada ao fato de apresentar menor nebulosidade durante o ano (CERQUEIRA JÚNIOR, 2014).

De acordo com Rodrigues (2016), os dados da AERONET são fornecidos em três níveis de qualidade: o nível 1.0, sem tratamento, incluindo todos os dados gerados, os quais podem ou não estarem contaminados pela presença de nuvens, o nível 1.5, cuja qualidade e precisão do dado é melhorada por meio de uma análise automática que remove a contaminação por nuvens e o nível 2.0, que retira as nuvens e assegura a qualidade dos dados. Para desenvolver este trabalho utilizou-se dados do nível 1.5 para os valores de AOD e coeficiente de Angstrom, uma vez que este era o melhor nível disponível para o conjunto de dados avaliado no período de 2013 a 2016. Cabe ressaltar que quando não havia dado disponível de ambos os parâmetros para uma data específica, foi pesquisado primeiramente o dado da mesma data disponível em outro nível e quando não havia êxito, optou-se pela data mais próxima disponível. Em seguida foi feito um levantamento da média diária dos valores da profundidade óptica na faixa de 500 nm (comprimento de onda mais

próximo de 550 nm disponibilizado pela AERONET) e coeficiente de Angstrom na faixa de 440-870 nm considerando cada data utilizada na geração do mosaico temporal de cada ano para cada carta (Apêndice 4). Ao final calculou-se as médias anuais para cada carta e enfim foram determinados os valores da visibilidade a serem utilizados no processamento do FLAASH, conforme consta na Tabela 10. O valor da visibilidade adotado para cada carta no processamento do FLAASH levou em consideração a média entre os valores obtidos a partir das equações propostas por Koschmieder (1924) e Deschamps et al. (1981)

Tabela 10 - Valores considerados para o cálculo da visibilidade do FLAASH

Carta_Ano	AOD (500 nm)	Coeficiente De Angstrom (440 -870 nm)	Vis. Koschmieder (Km)	Vis. Deschamps et al. (Km)	Vis. Final (Km)
SC-24-V-C_2013	0,098	0,487	40,06	32,56	36,31
SC-24-V-C_2014	0,092	0,883	42,61	37,62	40,12
SC-24-V-C_2015	0,180	0,745	21,69	26,12	23,90
SC-24-V-C_2016	0,127	0,653	30,73	30,40	30,56
SD-23-X-D_2013	0,121	0,372	32,25	28,20	30,23
SD-23-X-D_2014	0,088	0,866	44,24	38,11	41,18
SD-23-X-D_2015	0,245	0,709	15,96	21,12	18,54
SD-23-X-D_2016	0,263	0,657	14,88	19,52	17,20

3.6.4 Configurações de imagens Multiespectrais “Multispectral Settings”

Ao se inserir um dado multiespectral para proceder com a correção atmosférica, o FLAASH automaticamente habilita a opção para configuração de imagens multiespectrais. Neste momento o passo importante é designar as bandas do sensor que serão utilizadas para recuperar o vapor d’água e aerossóis. Entretanto, cabe ressaltar que caso nas opções *Water Retrieval* e *Aerosol Retrieval* seja escolhida a opção ‘não’, esta configuração torna-se desnecessária. Entretanto,

como neste trabalho foi feita a restauração de aerossóis, tornou-se necessária a definição dos canais *KT Upper* e *KT Lower* para as bandas 7 e 4, respectivamente, além da definição da banda 9 na opção *Cirrus Channel*. Os valores dos campos *Maximum Upper Channel Reflectance* e *Reflectance Ratio* foram mantidos conforme recomendação automática do FLAASH. Os valores destes dois campos são levados em consideração para identificar *pixels* escuros e estimar a visibilidade da imagem. Além disso, os valores recomendados pelo FLAASH são considerados acurados. No campo *Index to first band* foi colocado o valor 0, pois as bandas do *input* estavam em concordância com as bandas do arquivo *filter function*, garantindo, assim, uma boa correção.

Para o processamento de dados multiespectrais, um arquivo de resposta espectral, também conhecido como *filter function* é exigido pelo MODTRAN. Esse arquivo define a sensibilidade espectral de cada banda do instrumento multiespectral. O próprio software ENVI fornece estes arquivos para formatos multiespectrais suportados pelo FLAASH. Com o lançamento da versão 5.1 do ENVI, o FLAASH passou a suportar o sensor OLI do Landsat-8, o que incluiu a inserção do seu arquivo *filter function* correspondente. Assim, quando o ENVI abre os arquivos de dados Landsat-8 utilizando o arquivo *_MTL.txt*, as bandas do visível e SWIR são abertas como sendo um único arquivo MTL, enquanto as bandas termais, pancromática e *cirrus* são abertas separadamente. Entretanto, o FLAASH da versão 5.1 do ENVI inclui a banda 9 (*Cirrus*), o que acaba causando uma incompatibilidade das bandas do visível e SWIR com o arquivo *filter function* presente na versão 5.1 do ENVI, resultando em dados nulos para a banda 6 (SWIR) após processar o FLAASH. Desta forma, para proceder com o processamento foi feito um novo arquivo *filter function* para ser inserido no campo apropriado de modo que as bandas 8 e 9 fossem, respectivamente a pancromática e a *Cirrus*.

3.6.5 Configurações Avançadas

A altura de escala do aerossol (*Aerosol Scale Height*) é definida por Turner et al. (2001) como a altura inferior pela qual a profundidade óptica do aerossol atinge 63% da sua camada inteira. Entretanto, tendo em vista que os valores variam entre

1 e 2 km, neste trabalho optou-se por manter o valor recomendado pelo FLAASH, ou seja, 1,5 km.

Os dados utilizados para preencher o campo correspondente ao CO₂ (CO₂ *Mixing Ratio*) foram obtidos após consulta do site do NOAA (ftp://aftp.cmdl.noaa.gov/products/trends/co2/co2_mm_mlo.txt). Para cada carta foi feita uma média envolvendo os dados de CO₂ do período abrangido pelos mosaicos. A Tabela 11 apresenta os valores utilizados executar o FLAASH para cada carta considerando seu ano de abrangência.

Tabela 11 - Taxa de CO₂ utilizada para cada ano processado no FLAASH

ANO	TAXA DE CO₂ (ppm)
2013	396
2014	398
2015	400
2016	403

O preenchimento dos parâmetros de geometria, ou seja, os campos correspondentes aos ângulos zenitais e azimutais, não foi necessário para nenhuma carta, pois todas as imagens utilizadas para composição dos mosaicos temporais possuem uma geometria de visada no nadir (vertical). O preenchimento desse campo é obrigatório apenas para cenas geradas a partir de um campo de visada off-nadir.

Os demais parâmetros das configurações avançadas foram mantidos conforme recomendação do FLAASH, pois tratam de opções que não se aplicam ao Landsat ou ainda que visam obter um resultado mais acurado com o melhor tempo possível de processamento.

Tabela 12 - Demais parâmetros mantidos para o FLAASH (*Default*)

PARÂMETRO	OPÇÃO ESCOLHIDA
Use Square Slit Function	No
Use Adjacency Correction	Yes
Reuse MODTRAN Calculations	No
MODTRAN Resolution	15 cm ⁻¹

MODTRAN Multiscatter Model	Scaled DISORT
Number of DISORT Streams	8
Use Tiled Processing	Yes
Tile Size (Mb)	100
Output Reflectance Scale Factor	10000
Automatically Save Template Files	Yes
Output Diagnostic Files	No

3.7 Processamento do QUAC

O dado de entrada para o QUAC pode estar em radiância, reflectância aparente ou ainda em números digitais. Entretanto, para uma comparação mais consistente com o FLAASH foram utilizados dados de radiância como *input*. Além disso, o módulo ainda suporta dados nos formatos BIL, BIP e BSQ, e é requisito obrigatório que o *input* seja um arquivo que contenha no mínimo três bandas com seus respectivos comprimentos de onda válidos.

Os parâmetros para executar o QUAC são muito mais simples. Primeiramente foi criado um arquivo contendo apenas as bandas do OLI e foram definidos os comprimentos de onda para cada banda, utilizando arquivo ASCII com dados similares ao da Tabela 7. Na janela de parâmetros do QUAC a única informação solicitada é o tipo do sensor, o qual é definido automaticamente assim que o *input* é inserido, e a seleção do diretório de destino da nova imagem a ser gerada em reflectância de superfície, cujos valores são gerados numa escala de 10.000.

3.8 Modelagem Espectral de Mistura (MEM)

A técnica MEM permite estimar a composição do *pixel* em termos de componentes puros (assinaturas espectrais). A MEM aplicada no MapBiomias utiliza uma biblioteca espectral definida por quatro componentes puros: Vegetação, Vegetação Não-Fotossinteticamente Ativa, Solo e Nuvem (Figura 19). Essa biblioteca espectral foi definida originalmente para o bioma Amazônia, de acordo com estudo desenvolvido por Souza Jr. (2005).

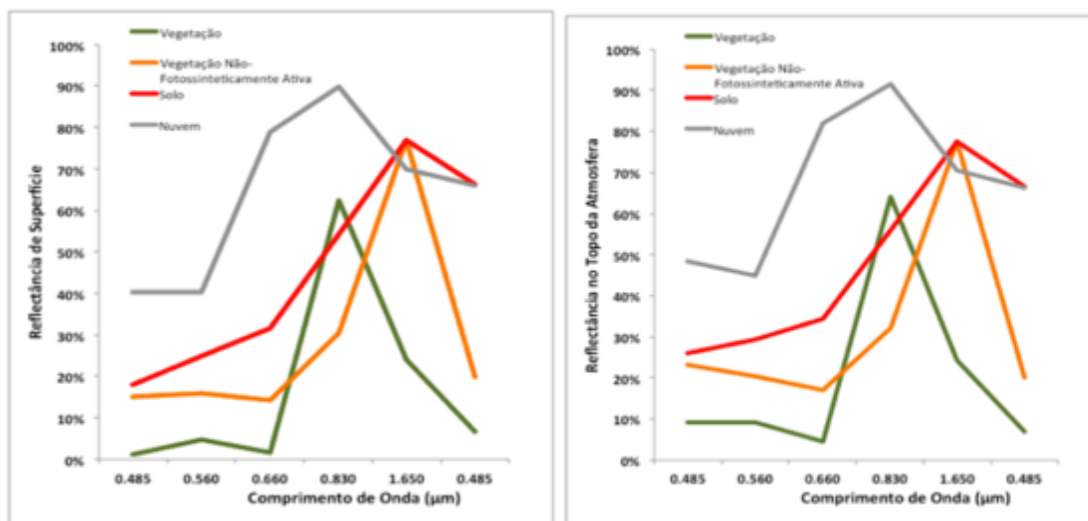


Figura 19 - Biblioteca Espectral para quatro componentes puros, em reflectância de superfície e no topo da atmosfera

A MEM assume que a reflectância de cada *pixel*, em cada banda da imagem Landsat, resulta da combinação linear do produto do percentual do componente puro (leia-se, a proporção no *pixel*) pelo seu respectivo valor na banda, com base na Equação 22.

$$Rb = F_i R_{i,b} + \epsilon b \quad (22)$$

Em que: Rb é a reflectância na banda b , $R_{i,b}$ é a reflectância do componente puro i , na banda b , F_i a fração (ou proporção) do componente puro i , cuja a soma é 1 (ou 100%), e ϵb é o erro residual de cada banda.

A MEM é resolvida para estimar os valores F_i (p. ex., a fração ou proporção do componente puro), obtendo, dessa forma, imagens Fração para Vegetação, Vegetação Não-Fotossinteticamente Ativa, Solo e Nuvem, as quais foram utilizadas para o cálculo do índice espectral NDFI, obtido pela diferença normalizada da imagem Fração Vegetação e da soma das imagens Fração Vegetação Não-Fotossinteticamente Ativa e Solo, de acordo com a Equação 23:

$$NDFI = \frac{Vegetação_s - (Vegetação Não Fotossinteticamente Ativa + Solo)}{Vegetação_s + Vegetação Não Fotossinteticamente Ativa + Solo} \quad (23)$$

Em que:

$$Vegetação_s = \frac{Vegetação}{100 - Sombra}$$

$$Sombra = 1 - \Sigma F_i$$

As imagens fração e o NDFI são utilizados como parâmetros de entrada para classificação da cobertura do solo.

3.9 Classificação da Cobertura do Solo

3.9.1 Caracterização das Classes

As imagens fração obtidas a partir do Modelo Espectral de Mistura são utilizadas na classificação da cobertura do solo para as seguintes classes: Agropecuária, Água, Área Não Vegetada, Área Úmida, Floresta Aberta, Floresta Densa e Outras Formações Nativas Não Florestais. É importante fazer algumas ressalvas: a classe “Agropecuária” envolve tanto cultivos agrícolas quanto áreas de produção pecuária, como pastagens. A classe “Outras Formações Nativas Não Florestais” envolve fitofisionomias que não possuem um aspecto florestal, ou seja, com um menor porte e um maior espaçamento entre as espécies arbóreo-arbustivas. Com isso, tendo como base uma abordagem bastante genérica e abrangente esta classe será denominada deste ponto em diante na legenda dos mapas e nos textos que seguem de Savana, para ser melhor associada com esse padrão de vegetação inerente ao bioma Caatinga: a savana estépica.

Assim, em termos bastante genéricos, a classe de Floresta Densa buscou englobar áreas com frações vegetais vigorosas, com elevada densidade e atividade fotossintética. A classe Floresta Aberta, por sua vez, englobou áreas da savana estépica arborizada, com maior espaçamento entre a vegetação. A classe Savana englobou um padrão característico da savana parque, com um padrão ainda maior de espaçamento entre a vegetação, sendo essas predominantemente de pequeno porte.

Outro ponto que merece ressalva é o fato de as referidas classes apontadas no parágrafo anterior serem adotadas pelo MapBiomas e aplicadas, com a mesma nomenclatura que foram apresentadas, para outros biomas brasileiros. Com isso, torna-se necessário e fundamental que haja uma descrição do que é abrangido por

cada uma das classes adotadas, especialmente as que envolvem formações vegetais. De antemão, é importante que fique claro que o principal intuito é diferenciar essas classes quanto ao nível de abundância da vegetação, de onde infere-se densidade, proximidade e tipos das formações florestais e campestres. A Tabela 13 apresenta uma descrição do que é considerado para cada classe:

Tabela 13 - Caracterização das Classes de Cobertura do Solo Mapeadas

CLASSES	DESCRIÇÃO
Agropecuária	Terra utilizada para a produção de alimentos. Incluem-se, também, terras em descanso, lavouras temporárias, permanentes e pastagens plantadas.
Água	Incluem-se todas as classes de água, tais como: rios, riachos, lagos naturais, reservatórios artificiais, etc.
Áreas Não Vegetadas	Cobertura da terra de natureza variada, tais como áreas urbanas, afloramentos rochosos, solo exposto.
Floresta Aberta	Baseando-se no Manual Técnico de Vegetação do IBGE (2012): savana-estépica arborizada
Floresta Densa	Baseado no Manual Técnico de Vegetação do IBGE (2012): floresta estacional decidual e semidecidual, e savana estépica-florestada e savana-estépica arborizada.
Savana	Baseado no Manual Técnico de Vegetação do IBGE (2012): savana-estépica parque, savana-estépica gramíneo-lenhosa

3.9.2 *Árvore de Decisão*

A classificação é conduzida seguindo alguns passos. Primeiro, é aplicada uma máscara de nuvens para mapear áreas cobertas por nuvens que não puderam ser filtradas durante o processo de geração do mosaico temporal da carta. Esse procedimento é feito por meio do algoritmo FMASK. Em seguida, é aplicada uma árvore de decisão, definida empiricamente para mapear cada classe (Figura 20). A árvore de decisão utilizada para a Caatinga é também utilizada para todos os demais biomas brasileiros. Isso explica a generalização de classes, especialmente quanto à vegetação.

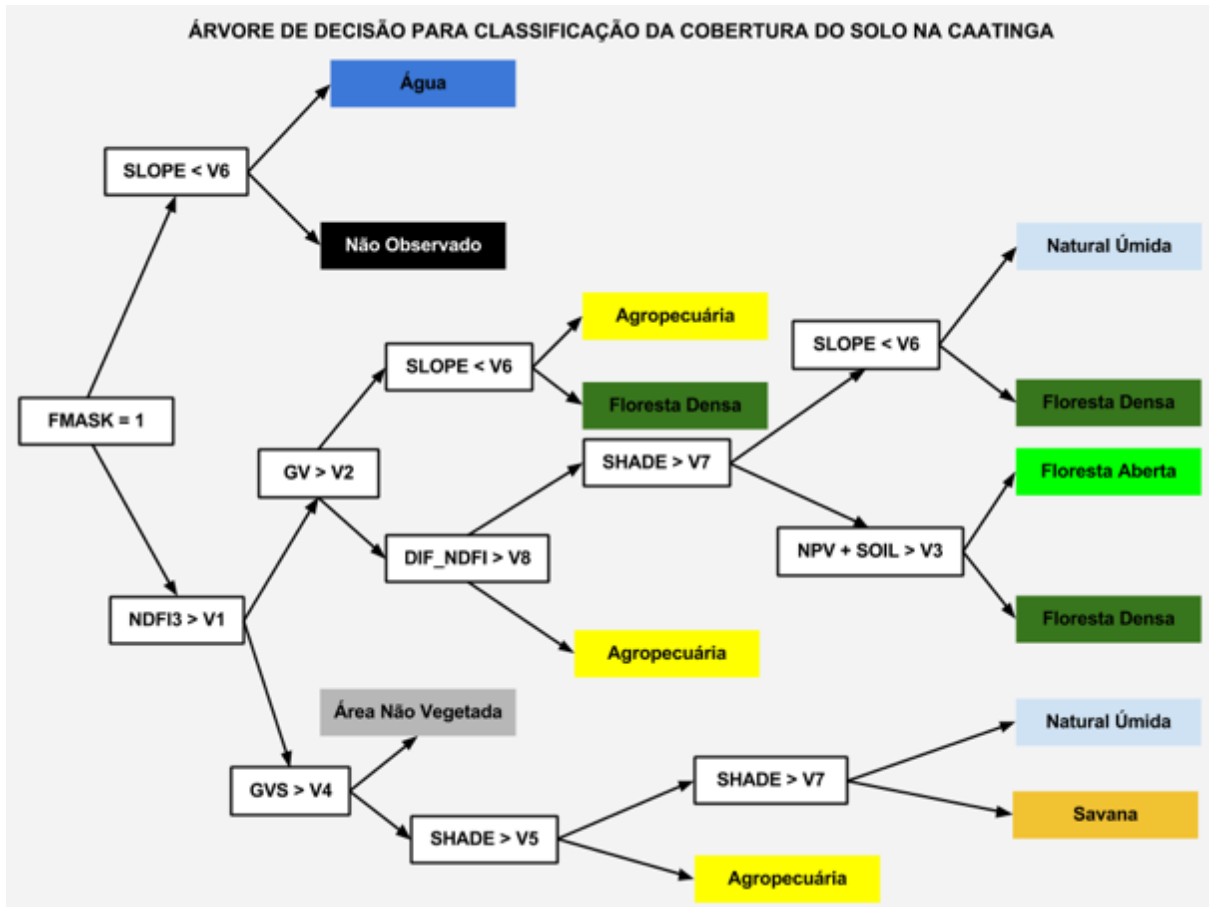


Figura 20 - Árvore de Decisão utilizada para parametrizar a classificação da cobertura do solo das cartas da Caatinga. Os nós representam os parâmetros utilizados para separar as classes que constam nos quadros coloridos. Legenda: DIF_NDFI – Amplitude do índice NDFI; NPV – Vegetação não fotossinteticamente ativa. GV – Vegetação Verde. GVS – Fração da vegetação verde normalizada pela sombra. NDFI3 – índice normalizado de diferença de fração ajustado para a Caatinga. SHADE – Sombra. SLOPE – Declividade. SOIL – Solo.

Os valores apresentados em cada nó da árvore de decisão foram parametrizados diferentemente para cada carta e ano, o que a torna o principal subsídio para fornecer a melhor decisão do que corresponde cada *pixel* classificado. Essa etapa foi desenvolvida com base em informações empíricas e a junção dos parâmetros apresentados na Árvore de Decisão podem ser editadas na tabela disponível em nuvem no *Google Drive*, denominada *Fusion Table* (Tabela 14). Isso permite com que sejam facilmente editados e inseridos no *script* sempre que for necessário fazer adaptações ou buscar melhores resultados, considerando os parâmetros existentes.

Tabela 14 - Valores adotados para cada parâmetro da Árvore de Decisão

CARTA	ANO	V1	V2	V3	V4	V5	V6	V7	V8
-------	-----	----	----	----	----	----	----	----	----

SC-24-V-C	2013	158	65	7	24	52	10	100	250
	2014	170	65	7	21	50	10	100	250
	2015	170	80	7	21	50	10	100	250
	2016	168	80	7	21	50	10	100	250
SD-23-X-D	2013	158	65	7	20	47	10	100	250
	2014	172	65	7	21	48	10	100	250
	2015	170	80	7	21	48	10	100	250
	2016	170	80	7	21	48	10	100	250

O ponto de partida para a interpretação da árvore é o algoritmo FMASK. Conforme já foi explicitado anteriormente, o valor do algoritmo igual a 1 representa água. A escolha desse parâmetro como raiz parte do princípio de que a água é um alvo facilmente identificado e que se confunde menos com os principais alvos presentes na cobertura do solo. Por isso a criação dessa máscara de água como pontapé inicial da árvore de decisão. Entretanto, para padronizar o processamento para todos os métodos com e sem correção utilizados verificou-se empiricamente que considerar o parâmetro SHADE (sombra) com valor a partir de 85 foi bastante relevante para servir como raiz da árvore de decisão. Em seguida os ramos que dão origem aos nós declividade e índice NDFI3 (que se trata de um ajuste do índice NDFI convencional) produzem um forte impacto na distinção dos demais alvos, especialmente os alvos vegetais.

Por ser um índice normalizado, o NDFI varia de -1 a 1. O NDFI3 foi ajustado para o MapBiomas a partir do índice NDFI convencional, que foi originalmente proposto para a Amazônia. Neste ajuste basicamente foi retirada a vegetação não fotossinteticamente ativa do divisor e foi somada à vegetação verde no dividendo. Isso foi feito com o objetivo de minimizar o efeito da sazonalidade da caatinga no NDFI convencional, uma vez que o período seco afeta a vegetação no sentido de promover uma maior predominância da vegetação seca em detrimento da vegetação verde, minimizando os resultados que indicam maior predominância de solo exposto em períodos de seca, ou seja, reduzindo a variação do NDFI convencional. Com base nisso, para a árvore de decisão apresentada foi feito um reescalonamento dos valores do NDFI, os quais passaram a variar de 0 a 200, sendo que quanto maior a presença de vegetação verde e sombra, mais próximos de 200 ficam os valores. O

reescalonamento é feito por meio da soma do *pixel* após a aplicação do NDFI a 1, seguida da sua multiplicação por 100. Esse nó é responsável pela distinção entre um *pixel* que pode ser classificado como floresta densa ou floresta aberta, de um *pixel* que pode ser classificado como outra formação nativa não florestal, como o caso da savana-estépica.

O parâmetro DIF_NDFI calcula a amplitude do índice NDFI ao longo do ano. Este parâmetro utiliza todas as imagens do mosaico do ano da carta para calcular a amplitude de variação do NDFI. Com isso, áreas de floresta por exemplo, tendem a ter uma menor amplitude enquanto que áreas agrícolas apresentam uma amplitude maior (solo exposto e vegetação vigorosa em um mesmo ano). Entretanto, a sazonalidade pode exercer uma influência considerável nesse parâmetro. Na seca, a amplitude das áreas agrícolas, que costumam ser maior, pode diminuir, gerando uma confusão espectral com áreas não vegetadas.

Os parâmetros GVS conforme já foi apresentado anteriormente refere-se à vegetação verde normalizada pela sombra, proposta por Souza Jr. et al. (2005). Os parâmetros GV, NPV, SOIL e SHADE se referem à vegetação verde, vegetação não fotossinteticamente ativa, solo e sombra, respectivamente, e seus valores são derivados do modelo espectral de mistura, o qual calcula uma fração para cada alvo a partir dos valores de reflectância obtidos com base no Modelo Espectral de Mistura. Assim, tratam-se de valores que podem variar de 0 a 100%. A sombra (SHADE) do Modelo Espectral de Mistura é calculada da seguinte forma: $100 - (GV + NPV + SOIL + CLOUD)$. Todos esses parâmetros são informados pelo MEM, inclusive o de nuvem (CLOUD). Além disso, é extremamente importante que fique claro que a sombra calculada pelo Modelo Espectral de Mistura não possui relação com a sombra removida pelo FMASK, que são oriundas de nuvens.

Conforme pode ser observado na árvore de decisão, o parâmetro sombra é bastante utilizado, aparecendo em três nós. É importante que os valores do V7 sejam sempre maiores que os valores de V5. O nó SHADE V5 aparece apenas para *pixels* com NDFI3 baixo e, conseqüentemente acaba sendo mais eficiente na diferenciação de áreas com pouca sombra, que geralmente são pastagem e áreas com aspectos vegetais gramíneo-herbáceo. Já para o caso de áreas alagadas (úmidas) costumam ser interpretadas como sombra, o que justifica valores maiores para este parâmetro com a variável V7.

A informação com relação à declividade (*slope*) é proveniente do SRTM – *Shuttle Radar Topographic Mission* –, que se trata de uma missão espacial para obter dados referentes ao modelo digital de terreno, e é usado para fazer correções mais simples, como vegetações com maior padrão de espaçamento entre si. Áreas com alto GV costumam ter pouca sombra e por isso são normalmente classificadas como áreas de agricultura. Entretanto, cabe fazer uma ressalva. Vertentes de alta declividade podem ter muita iluminação solar e por isso tendem a ser classificadas como agricultura, mesmo que se tratem de floresta densa. Isso faz com que a interferência da iluminação solar aliada à declividade seja determinante para diferenciar ambas as classes.

3.10 Pós-Classificação

3.10.1 Validação da Classificação

A avaliação da acurácia temática para as classificações foi feita a partir das seguintes etapas: definição do número de amostras necessárias para garantir a melhor qualidade possível da avaliação; distribuição aleatória dessas amostras nas imagens Landsat em composição colorida; checagem por interpretação visual; verificação da exatidão por meio do uso da matriz de confusão e cálculo dos índices de concordância de forma geral e por classe.

Como foram geradas 3 classificações por ano e por carta processada, teve-se como produto final um total de 24 classificações. Além disso, tendo em vista o fato de o procedimento descrito no parágrafo anterior ter como objetivo apontar o melhor dado de reflectância utilizado para gerar as classificações, logo não se fez necessária a comparação estatística entre as classificações para todos os anos, muito embora uma comparação temporal tenha sido feita em termos visuais para cada carta com o objetivo de identificar como a mudança na cobertura do solo se comportou diante de cada dado de 2013 a 2016. Dessa forma, foi escolhido um ano específico para avaliar estatisticamente o melhor dado de reflectância utilizado para classificar cada carta. Para isso, partiu-se do seguinte pressuposto: para uma carta, selecionou-se um ano cujo padrão de distribuição das classes demonstrasse maior

semelhança entre os métodos em termos visuais e, para outra carta, um ano cuja distribuição apresentasse maior divergência entre as classificações geradas. Com isso, concluiu-se pelo uso das imagens de 2015 para a carta SD-23-X-D e 2013 para a carta SC-24-V-C, tendo a primeira apresentado convergência e a segunda, divergência ao se comparar visualmente os resultados das classificações em termo de maior percentual de predominância de cada classe para os anos.

Na carta SD-23-X-D para o ano de 2015, a classe floresta aberta apresentou maior predominância em todos os métodos analisados. Já a carta SC-24-V-C para o ano de 2013, a classe referente às áreas não vegetadas predominou na classificação oriunda do dado de reflectância TOA, a classe savana juntamente com a classe de área não florestada prevaleceu praticamente de forma igualitária para o dado de reflectância de superfície obtida pelo QUAC. Ainda para essa mesma carta e ano, o dado de reflectância de superfície oriundo do FLAASH apresentou maior predominância da classe áreas não vegetadas.

Para o cálculo do número de amostras foi utilizado o método de distribuição multinominal (CONGALTON e GREEN, 2008), que leva em consideração o número de classes e a proporção da classe com maior área na classificação. Além disso, a unidade de amostragem utilizada para este trabalho foi o *pixel*, uma vez que a similaridade entre as informações espectrais de cada um serviu como embasamento para gerar a classificação de cada carta. Essa forma de validação, com base na estrutura de imagem de satélite, é bastante utilizada por permitir um levantamento ágil e de boa precisão (EPIPHANIO et al., 2002; MALDONADO, 2005; VALENTE, 2001), especialmente se comparado aos levantamentos de campo.

A Equação 24 exemplifica o cálculo de amostragem realizado para a carta SD-23-X-D, do ano de 2015, classificada a partir do dado em reflectância aparente (TOA). Para esse caso, N representa o número de amostras, B é obtido a partir de uma tabela de distribuição de qui-quadrado com um grau de liberdade de $1-\alpha/k$, onde k representa o número de classes, que neste caso são 6 ($k=6$). O programa Excel fornece esse parâmetro: basta colocar a fórmula [=INV.QUI(probabilidade; graus_liberdade)]. O nível de confiança desejado é de 95%, logo, tem-se 5% de erro admissível ($\alpha = 0,05$). Desta forma, $B(x^2_{(1,0,991666)} = 6,96757291)$, Π_i representa a proporção da classe com maior área na classificação, que neste caso é 57,10% ($\Pi_i = 0,571$). Esse dado foi verificado para cada classificação, de cada carta, por meio

da ferramenta *Model Builder* do ArcGIS, onde criou-se um fluxo para a inserção de um campo na tabela de atributos de cada imagem *raster*, denominado “Percentual”, o qual, a partir da fórmula inserida na ferramenta *Field Calculator*, foi preenchido com o valor correspondente em percentual de cada classe. Por fim, b , corresponde ao máximo erro admissível quanto ao número apropriado de amostras, neste caso 5% ($b = 0,05$). Assim para o caso desta área, o tamanho da amostra seria:

$$N = \frac{B\Pi_i(1 - \Pi_i)}{b^2}$$

$$N = \frac{6,96757291 \cdot 0,571(1 - 0,571)}{0,05^2}$$

$$N = \frac{1,70676969246069}{0,0025} \quad (24)$$

$$N = 682,70 \cong 683$$

A Tabela 15 mostra os resultados dos cálculos para tamanho de amostra mínima para cada classificação gerada em cada carta/ano selecionados para análises estatísticas, de onde foi determinado-se os maiores valores para gerar os pontos de referência, garantindo uma maior representatividade, conforme os valores destacados na tabela.

Tabela 15 - Valores da amostragem mínima indicada para cada carta a ser avaliada com destaque para o maior valor encontrado

CARTA_ANO	PRODUTO LC8_L1T_TOA	QUAC	FLAASH
SD-23-X-D_2015	683	601	687
SC-24-V-C_2013	693	628	696

Definido o tamanho da amostra para cada carta avaliada, realizou-se uma amostragem aleatória simples para cada uma das duas imagens Landsat, por meio da ferramenta *Hawths Analysis Tools* disponível no software ArcGIS 10.2, o qual foi utilizado como espaço amostral um arquivo de pontos do centroide de cada *pixel* das imagens de cada carta (Figuras 21 e 22). O passo seguinte caracterizou-se pela atribuição das classes correspondentes a cada amostra por meio de interpretação visual na tela do computador, utilizando a imagem ao fundo, além do auxílio do aplicativo *Google Earth*. Esses pontos foram checados e classificados com rigor

para então serem utilizados como dados de referência (verdade de campo) para construir a matriz de confusão, a qual permitiu computar a exatidão global e os coeficientes de concordância total e por classe.




Figura 21 - Distribuição aleatória dos pontos na carta SC-24-V-C para criar a verdade de campo (referência)

Amostragem Aleatória da Carta SD-23-X-D




Figura 22 - Distribuição aleatória dos pontos na carta SD-23-X-D para criar a verdade de campo (referência)

4 RESULTADOS E DISCUSSÃO

A informação derivada dos dados de sensores remotos, de acordo com Jensen (2009), é geralmente apresentada como uma imagem realçada, um mapa-imagem, mapas temáticos, arquivos espaciais em banco de dados, estatísticas ou gráficos. No caso deste trabalho os resultados serão dispostos em mapas e análises estatísticas, a fim de contribuir da melhor maneira possível para que seja feita uma avaliação sob as duas perspectivas, as quais uma vez complementadas, garantem que um panorama melhor seja gerado acerca dos dados gerados.

Com isso, a estrutura deste capítulo se dará da seguinte forma: primeiramente serão mostrados os resultados da carta SC-24-V-C do ano de 2013 e da carta SD-23-X-D para o ano de 2015 com as análises estatísticas propostas. Assim, para essas cartas serão exibidas a imagem da classificação de cada dado de reflectância e sua matriz de confusão correspondente, a qual serviu como base para o cálculo dos índices de concordância global (*Exatidão*, *Kappa* e *Tau*). Em seguida, serão apresentadas as tabelas que permitirão analisar os mesmos índices de concordância, porém com foco em cada classe individualmente (*Kappa* condicional e exatidões do produtor e usuário), o que, ao final, permitirá avaliar os resultados das classificações sob uma perspectiva sistêmica e também compartimentada acerca dos resultados obtidos. Essas análises também apontarão eventuais erros de comissão e omissão associados às classificações. A soma desses fatores permitirá identificar dentre os dados com e sem correção atmosférica, o que melhor se ajusta às classificações para a Caatinga.

Posteriormente será feita uma discussão acerca dos principais fatores que podem ter influenciado positiva ou negativamente na geração das classificações com e sem correção atmosférica e seu impacto nos alvos do bioma Caatinga. Ao final, será feita também uma análise visual comparativa entre as classificações para ambas as cartas em todos os quatro anos estudados (2013 a 2016). A junção desses parâmetros avaliativos fornecerá subsídios mais concisos para uma discussão mais apurada com relação às principais causas que podem explicar os fenômenos observados, além dos fatores que podem estar associados direta ou indiretamente a cada comportamento observado no estudo.

4.1 Classificação da Cobertura do Solo para a Carta SC-24-V-C

Ao se fazer uma análise visual do mapa de classificação da cobertura do solo a partir do dado em reflectância no topo da atmosfera verifica-se uma predominância da classe áreas não vegetadas, seguida da classe floresta aberta (Figura 23).

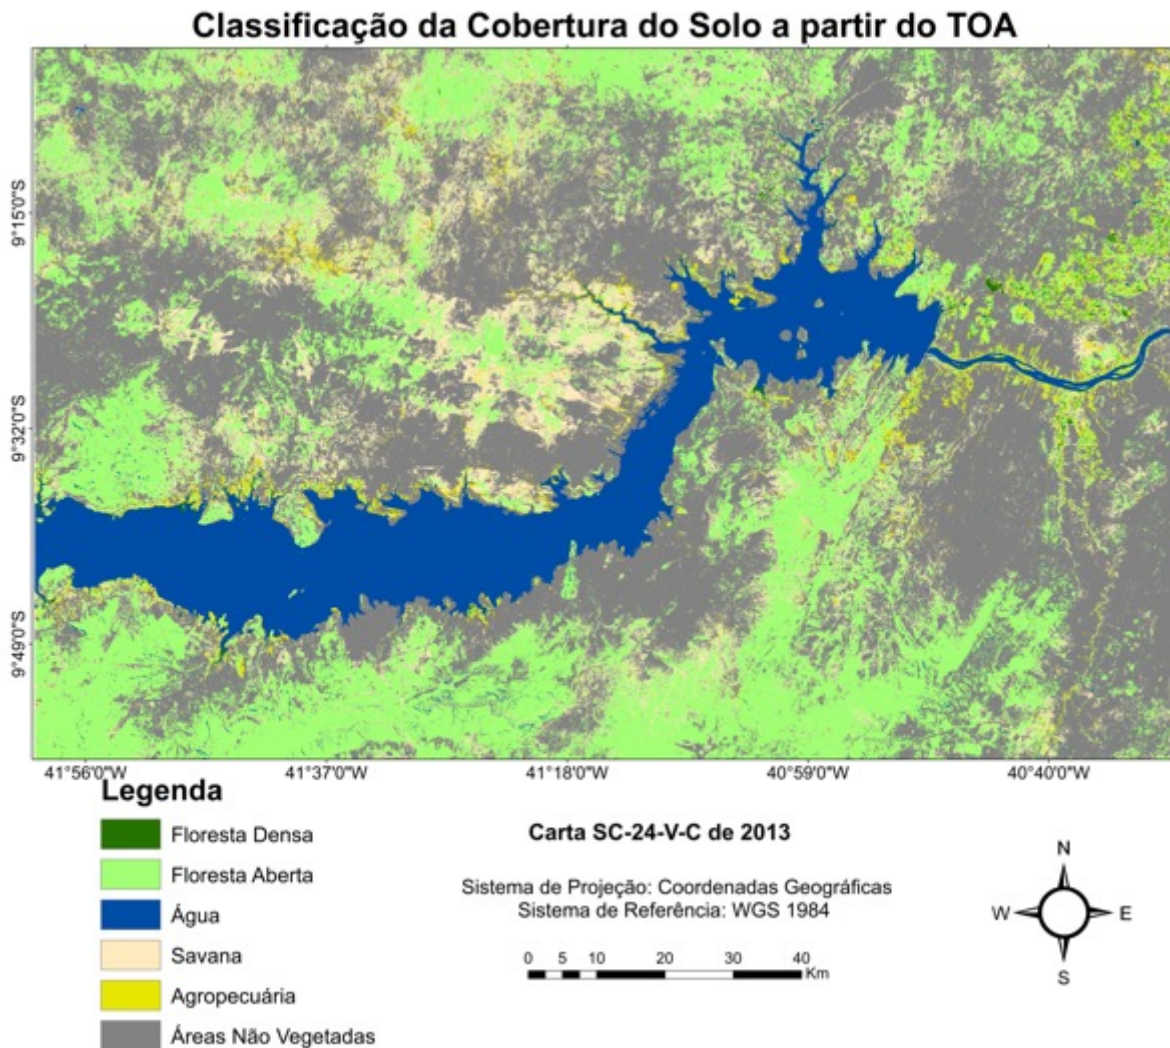


Figura 23 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado em reflectância no topo da atmosfera (aparente) do dado LC8_L1T_TOA processado pelo Google Earth Engine

As classes savana e agropecuária aparecem em menor proporção. A água foi classificada adequadamente e praticamente não foi detectada floresta densa. A Tabela 16 apresenta a matriz de confusão para essa classificação.

Tabela 16 - Matriz de Confusão da classificação oriunda a partir do produto LC8_L1T_TOA para a carta SC-24-V-C do ano de 2013

Referência (Verdade) Classificação	Agropecuária	Água	Áreas Não Vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	6	-	3	-	-	5	14
Água	-	65	-	-	-	-	65
Áreas Não Vegetadas	9	-	133	48	-	116	306
Floresta Aberta	6	-	1	169	11	36	223
Floresta Densa	1	-	-	-	-	-	1
Savana	2	-	2	25	1	57	87
Total	24	65	139	242	12	214	696

Observando a matriz de confusão é possível constatar que de um total de 696 pontos distribuídos aleatoriamente sobre a carta e que representam os dados de referência (verdade de campo), 430 se mostraram concordantes com a classificação. Isso representa uma exatidão global de 61,78%, *Kappa* de 49,24%, considerado bom, e *Tau* de 54,13%. A classificação de Landis e Koch (1977), proposta para o índice *Kappa*, ao se considerar para os valores do *Kappa* condicional, o dado em reflectância aparente pode ser considerado excelente para a água, muito boa para a floresta aberta, boa para as classes agropecuária e savana, razoável para as áreas não florestadas e péssima para a floresta densa.

A classe água apresentou nível de concordância de 100% com a classificação, tanto sob a perspectiva do produtor como do usuário, o que resultou em erros de comissão e omissão nulos para a classe. Já a classe que apresentou o pior resultado foi a floresta densa, não apresentando nenhuma concordância, com exatidões nulas e 100% de erros tanto de omissão quanto de comissão. Entretanto, de 696 pontos amostrados, houveram apenas 12 pontos de referência para a classe (menos de 2% da totalidade de pontos amostrais), o que mostra que se trata de uma classe pouco presente na carta específica e que também pode ter sido subestimada pelo dado de reflectância no topo da atmosfera.

A classe savana foi muito confundida com áreas não vegetadas, o que influenciou consideravelmente para uma exatidão do produtor de apenas 26,63% e um erro de omissão de 73,37%. No que diz respeito à exatidão do usuário, o valor obtido foi de 65,51%, com consequentes erro de comissão de 34,49%, o que se

deve ao fato de a classe ter sido incluída erroneamente em classes que não pertence na realidade, como por exemplo a classe floresta aberta. Já a classe floresta aberta teve um maior nível de concordância com os pontos de referência, com exatidões do produtor e do usuário de, respectivamente, 69,83% e 75,78%. Das classes de vegetação, essa foi a que apresentou o maior nível de concordância, indicando que boa parte dos *pixels* concordam com a maioria dos pontos amostrados (verdade de campo), além de indicarem elevada probabilidade de os *pixels* serem considerados floresta aberta, de fato. Os erros de omissão e comissão foram de 30,17% e 24,22%, respectivamente.

A classe agropecuária apresentou baixa concordância com os pontos amostrais e com a classificação em geral, apresentando erros de omissão e comissão de 75% e 57,14%, respectivamente. Em outras palavras isso quer dizer que apenas 25% dos *pixels* considerados áreas de agropecuária foram corretamente identificados como tais, enquanto que 42,86% é a probabilidade das áreas classificadas como agropecuária corresponderem com a verdade terrestre, tendo os demais sido classificados como áreas não vegetadas ou savana. Já a classe referente às áreas não vegetadas teve duas perspectivas bem distintas. Do ponto de vista do produtor, obteve-se uma exatidão de 95,68%, porém sob a perspectiva do usuário, a exatidão foi de 43,46%. Ou seja, o erro de comissão de 57,14% engloba majoritariamente a classe savana.

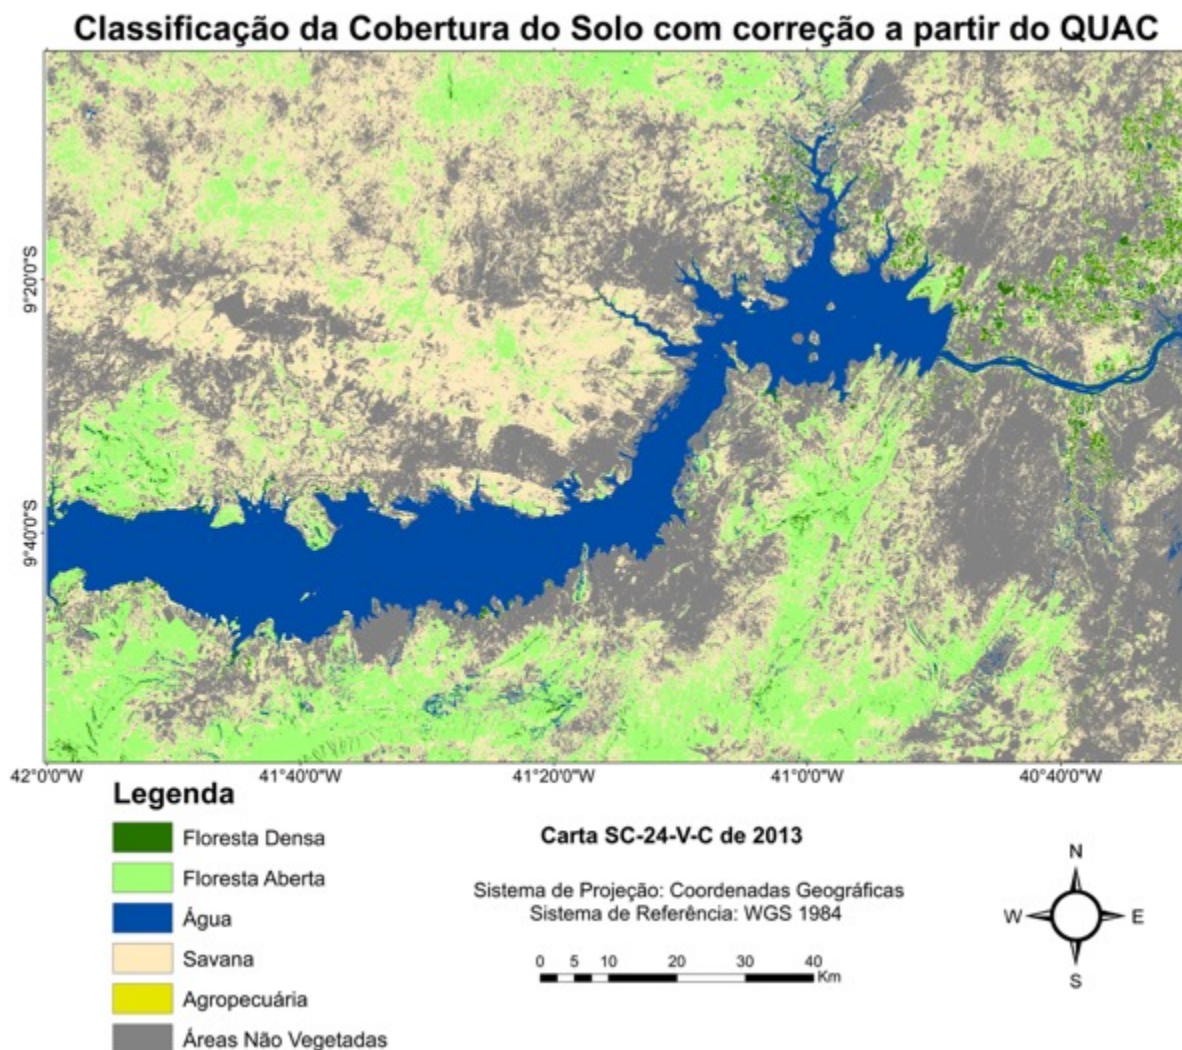


Figura 24 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado com correção atmosférica a partir do QUAC

Analisando visualmente o mapa de classificação da cobertura do solo a partir do dado em reflectância de superfície gerado a partir do QUAC para a carta SC-24-V-C do ano de 2013, verifica-se que as classes savana e áreas não vegetadas aparecem quase na mesma proporção, sendo as com maior abrangência na imagem. A classe floresta aberta foi subestimada em comparação à classificação resultante do dado sem correção atmosférica. Já a classe floresta densa, que no dado sem correção atmosférica praticamente não apareceu, passou a se destacar mais na referida classificação. A água também foi classificada adequadamente e praticamente não foi detectada áreas de agropecuária. A Tabela 17 apresenta a matriz de confusão para a classificação oriunda do dado produzido pelo QUAC.

Tabela 17 - Matriz de Confusão da classificação oriunda a partir dos dados com correção atmosférica gerados pelo QUAC

Referência (Verdade) Classificação	Agropecuária	Água	Áreas não vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	-	-	-	-	-	-	-
Água	1	65	1	1	-	1	69
Áreas não vegetadas	8	-	121	21	1	67	218
Floresta Aberta	3	-	-	128	6	9	146
Floresta Densa	4	-	-	2	2	-	8
Savana	8	-	17	90	3	137	255
Total	24	65	139	242	12	214	696

A matriz de confusão mostra que 453 *pixels* de um total de 696 se mostraram concordantes com os resultados oriundos da classificação, o que representa uma exatidão global de 65,08%, *Kappa* de 52,97% – considerado bom, assim como a classificação a partir do dado sem correção atmosférica, apesar do aumento de 3,73% – e *Tau* de 58,10%. Considerando a escala de qualidade de Landis e Koch (1977) para cada classe individualmente aplicada aos valores do *Kappa* condicional, o dado com correção atmosférica a partir do QUAC demonstrou-se excelente para as classes água e floresta aberta, boa para as áreas não vegetadas, razoável para as classes floresta densa e savana e péssima para a agropecuária.

A água apresentou níveis de concordância bastante elevados, tanto sob a perspectiva do produtor como do usuário, sendo de 100% e 94,20%, respectivamente. O erro de comissão de 5,79% foi distribuído em três classes – áreas não vegetadas, floresta aberta e savana – sendo um *pixel* para cada uma. Já a classe que apresentou o pior resultado foi a agropecuária, não apresentando nenhuma concordância, com exatidões nulas, porém, tendo apresentado uma variação discrepante entre os erros de omissão e comissão, sendo de 100% e 0%, respectivamente. Isso quer dizer que todos os *pixels* referência correspondentes a áreas de agropecuária foram excluídos dessa classe enquanto que do ponto de vista da classificação, nenhum foi atribuído a uma classe à qual não pertence na realidade.

Dentre as classes de vegetação, os *pixels* de referência que foram classificados corretamente, ou seja, que apresentaram maior exatidão do produtor foram os correspondentes às classes savana, floresta aberta e floresta densa, respectivamente, com 64,01%, 52,89% e 16,66%. Já as classes que apresentaram maior exatidão do usuário foram a floresta aberta, com 87,67%, savana, com 53,72% e floresta densa, com 25%. Comparando com a classificação sem correção atmosférica, percebe-se um aumento da representatividade da floresta densa para a carta nessa classificação, mesmo ainda apresentando baixos valores estatísticos de exatidão. A classe savana se confundiu com áreas não vegetadas, assim como na classificação a partir de dados sem correção atmosférica, porém em menor escala. O erro de omissão para a classe foi de 35,99% enquanto o erro de comissão, 46,28%. Já os erros para a floresta aberta foram de 47,11% (omissão) e 12,13% (comissão). Essa classe se confundiu bastante com a savana.

A classe referente às áreas não vegetadas apresentou exatidão do produtor de 87,05%, com erro de omissão de 12,95% associado, o que pode ser considerado baixo tomando por base a totalidade dos *pixels* referência. Já a exatidão do usuário foi mais baixa, sendo de 55,50%. Isso se deve ao fato de, dos *pixels* restantes, grande parte ter sido considerado savana, classe responsável em maior escala pelo erro de comissão de 44,50%.

Classificação da Cobertura do Solo com correção a partir do FLAASH

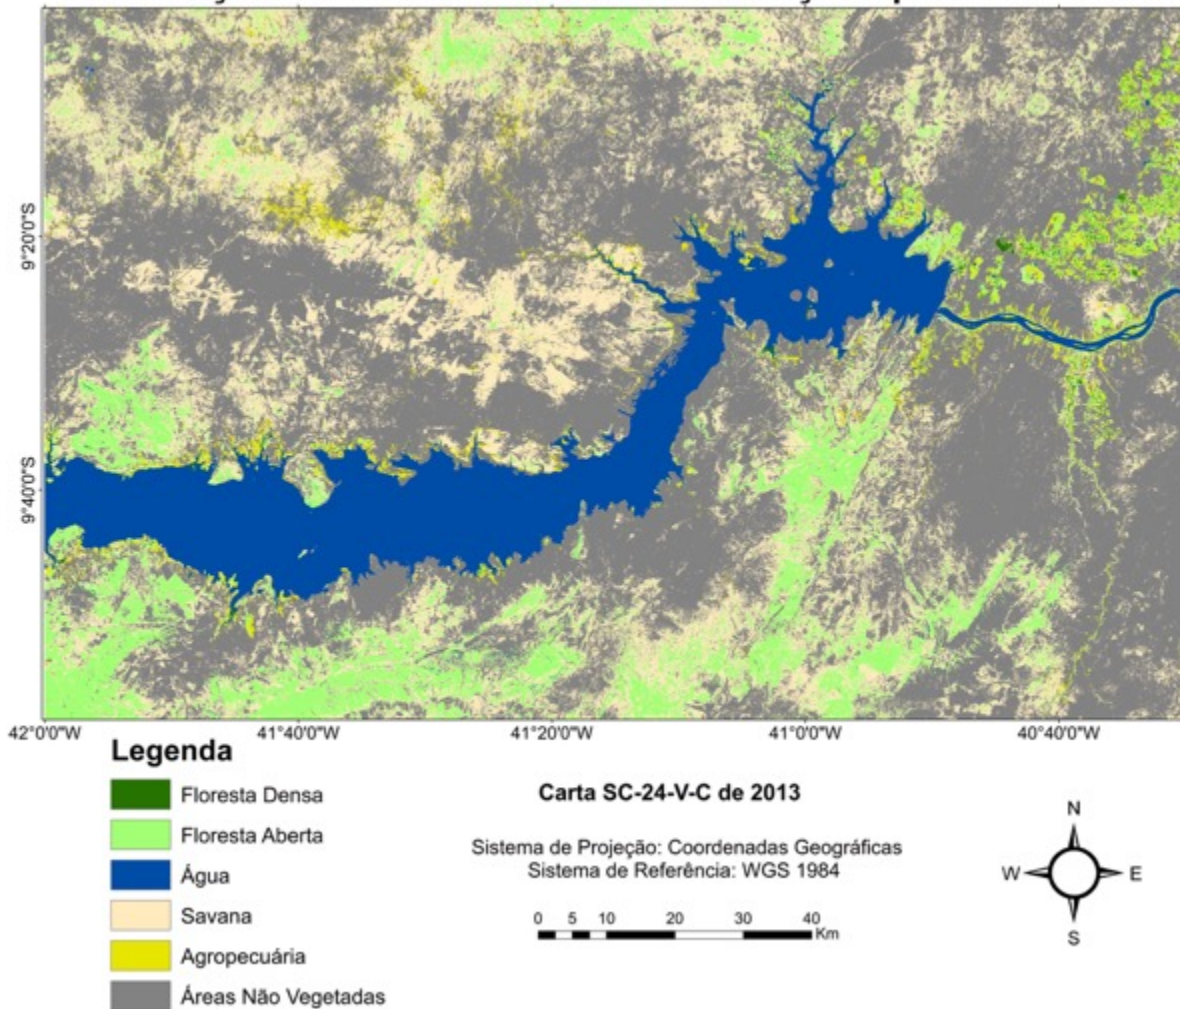


Figura 25 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SC-24-V-C de 2013 a partir do dado com correção atmosférica a partir do FLAASH

Ao avaliar visualmente o mapa de classificação da cobertura do solo a partir do dado em reflectância de superfície gerado pelo FLAASH verifica-se uma forte predominância das áreas não vegetadas, em mais de 50% da imagem. Em comparação com o dado sem correção atmosférica nota-se que há uma subestimação da floresta aberta. Já em comparação com o dado corrigido pelo QUAC houve uma subestimação tanto das classes savana como floresta aberta. Em relação às classes agropecuária e floresta densa, esse dado se assemelha mais com o dado sem correção atmosférica, uma vez que as referidas classes aparecem menos em relação à classificação com correção atmosférica pelo QUAC. A água foi classificada adequadamente. A Tabela 18 apresenta a matriz de confusão para essa classificação.

Tabela 18 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo FLAASH

Referência (Verdade) Classificação	Agropecuária	Água	Áreas não vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	7	-	3	1	-	6	17
Água	-	65	-	-	-	1	66
Áreas não vegetadas	10	-	133	69	4	132	348
Floresta Aberta	4	-	1	67	6	4	82
Floresta Densa	-	-	1	1	-	-	2
Savana	3	-	1	104	2	71	181
Total	24	65	139	242	12	214	696

A matriz de confusão permite constatar que apenas um total de 343 *pixels* concordaram entre si em relação à totalidade dos pontos considerados como referência. Isso representa uma exatidão global de 49,28%, *Kappa* de 34,08%, considerado ruim, e *Tau* de 39,13%. A classificação de Landis e Koch (1977), proposta para o índice *Kappa*, ao se considerar para os valores do *Kappa* condicional, o dado corrigido pelo FLAASH pode ser considerado excelente para a água, muito boa para a floresta aberta, ruim para as áreas não vegetadas e savana e péssima para as classes agropecuária e floresta densa. Esses dados já demonstram um forte indício de que os dados corrigidos pelo FLAASH menos se ajustam ao contexto da carta.

A água apresentou alto nível de concordância, tanto sob a perspectiva do produtor como do usuário, sendo de 100% e 98,48%, respectivamente. Já a classe que apresentou o pior resultado foi a floresta densa, não mostrando nenhuma concordância, com exatidões nulas e 100% de erros tanto de omissão quanto de comissão, da mesma forma como foi visto para o dado sem correção atmosférica. Outra classe que apresentou resultados baixos foram as áreas de agropecuária, com 29,16% de exatidão do produtor e exatidão do usuário nula. Isso demonstra, assim como visto nos dados corrigidos por meio do QUAC, uma variação discrepante entre os erros de omissão e comissão, sendo de 70,84% e 0%, respectivamente. Isso quer dizer que todos os *pixels* referência correspondentes a áreas de agropecuária foram excluídos dessa classe enquanto que do ponto de vista

da classificação, nenhum foi atribuído a uma classe à qual não pertence na realidade.

Dentre as demais classes de vegetação, a classe floresta aberta apresentou exatidões do produtor e usuário de, respectivamente, 27,78% e 81,70%, enquanto a classe savana não foi muito bem classificada, apresentando erros de omissão e comissão de 66,82% e 60,87%, respectivamente, o que mostra que tanto as exatidões do produtor como do usuário para essa classe não chegaram a 40%. A classe correspondente às áreas não vegetadas, por sua vez, apresentou resultados muito favoráveis sob a perspectiva da exatidão do produtor, com 95,68%. Já para a exatidão do usuário, apresentou 38,21% de concordância, o que mostra que vários *pixels* foram atribuídos a classes que não pertencem na realidade, como por exemplo, da classe savana, o que reforça a ampla confusão espectral entre essas classes.

4.2 Classificação da Cobertura do Solo para a Carta SD-23-X-D

Analisando visualmente o mapa de classificação da cobertura do solo a partir do dado em reflectância no topo da atmosfera para a carta SD-23-X-D do ano de 2015, verifica-se um maior predomínio das classes de vegetação, especialmente, as classes floresta aberta e densa (Figura 26).

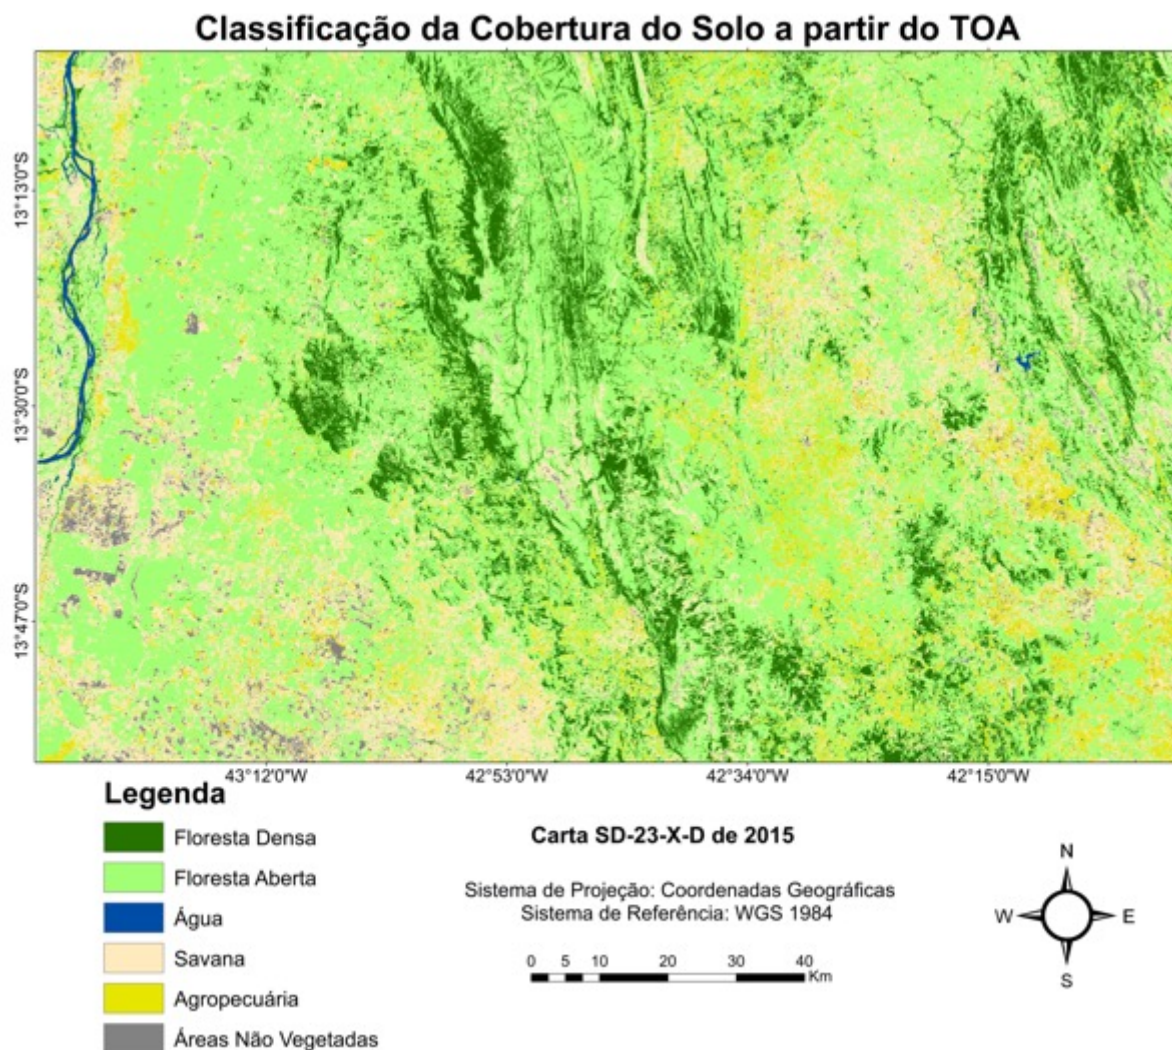


Figura 26 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado em reflectância no topo da atmosfera (aparente) processado pelo Google Earth Engine

A área representada por essa carta apresenta menor interferência antrópica do que a carta anterior, o que é bastante evidente. Além disso, a água, que é uma classe pouco presente na carta, também está bem representada. A Tabela 19 apresenta a matriz de confusão para a classificação oriunda do dado sem correção atmosférica para a referida carta.

Tabela 19 - Matriz de Confusão da classificação oriunda a partir do produto LC8_L1T_TOA para a carta SD-23-X-D do ano de 2015

Referência (Verdade) Classificação	Agropecuária	Água	Áreas não vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	45	-	8	2	-	5	60
Água	-	3	1	-	-	-	4
Áreas não vegetadas	5	-	7	-	-	2	14
Floresta Aberta	44	-	2	232	53	42	373
Floresta Densa	4	-	-	11	68	2	85
Savana	55	-	12	7	-	77	151
Total	153	3	30	252	121	128	687

Observando a matriz de confusão é possível constatar que de um total de 687 pontos distribuídos aleatoriamente sobre a carta e que representam os dados de referência (verdade de campo), 432 se mostraram concordantes com a classificação. Isso representa uma exatidão global de 62,88%, *Kappa* de 48,28%, considerado bom, e *Tau* de 55,45%. Considerando a escala de qualidade de Landis e Koch (1977) para cada classe individualmente aplicada aos valores do *Kappa* condicional, a classificação oriunda do dado em reflectância aparente pode ser considerada muito boa para a água, agropecuária e floresta densa, e boa para as classes áreas não vegetadas, floresta aberta e savana. De modo geral é possível notar que não houveram variações muito extremas entre as classes, ou seja, da mesma forma que não houve qualidade excelente, não houve também ruim ou péssima.

A água apresentou exatidões de 100% e 75% para o produtor e usuário, respectivamente. Já o pior resultado observado foi para a classe referente às áreas não vegetadas, que apresentaram erros de omissão e comissão de, respectivamente, 76,66% e 50%. No entanto, comparando a quantidade de amostras dessa classe com as demais, observa-se uma quantidade bem reduzida, o que mostra menor predominância da mesma na carta. A classe água, apesar de ter apenas 3 pontos amostrais, apresentou elevada concordância em função da facilidade de diferenciação desse alvo em relação aos demais, uma vez que a água apresenta propriedades espectrais únicas.

Dentre as classes de vegetação, a que apresentou melhores resultados foi a floresta aberta, com exatidão do produtor de 92,06% e do usuário de 62,19%, seguida da classe floresta densa, com 56,19% e 80% e savana, com 60,15% e 50,99% para as exatidões do produtor e usuário, respectivamente. Do ponto de vista do produtor, a savana foi muito confundida com a floresta aberta, já sob a perspectiva do usuário, houve bastante confusão com a classe agropecuária. Por fim, a classe agropecuária apresentou erro de omissão elevado, de 70,58%, o que quer dizer que menos de 30% dos *pixels* foram de fato atribuídos corretamente à classe. Já em termos de erro de comissão, apresentou 25%, ou seja, cerca de um quarto dos *pixels* foram incluídos em uma classe a qual não pertencem de fato.

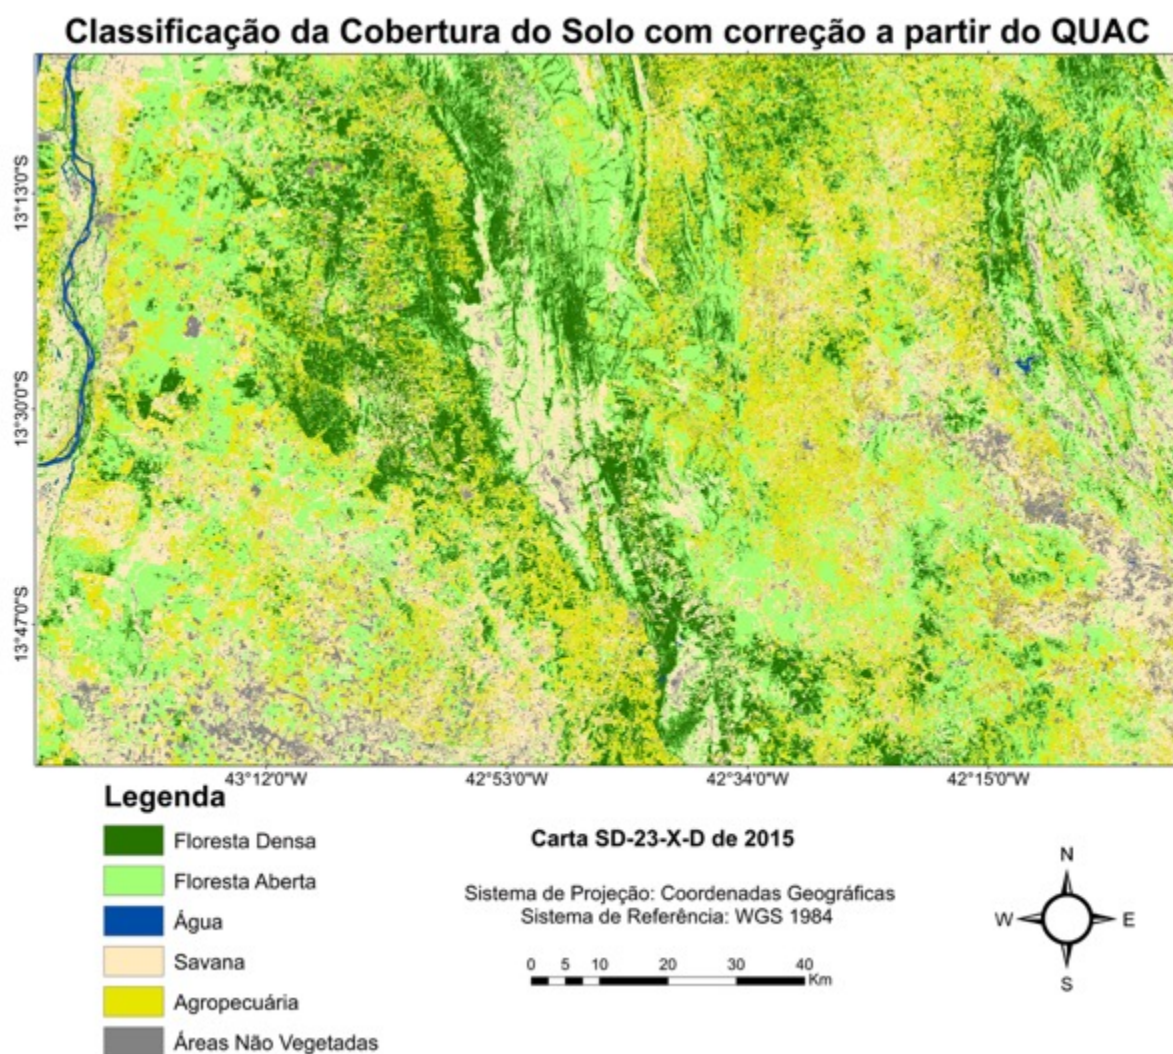


Figura 27 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado com correção atmosférica a partir do QUAC

Ao avaliar visualmente o mapa de classificação da cobertura do solo a partir do dado em reflectância de superfície gerado pelo QUAC ainda é possível observar o mesmo padrão de predomínio de áreas vegetadas na carta. Entretanto, em comparação com o dado sem correção atmosférica nota-se que há um aumento da savana e conseqüente redução das áreas de floresta aberta. Em relação às demais classes, mais uma vez a água foi bem representada e houve um aumento considerável das áreas de agropecuária. As áreas não vegetadas aparecem mais, mas com aumento sutil em relação ao dado TOA. A Tabela 20 apresenta a matriz de confusão para essa classificação.

Tabela 20 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo QUAC

Referência (Verdade) Classificação	Agropecuária	Água	Áreas não vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	99	-	2	26	-	12	139
Água	-	3	-	-	-	-	3
Áreas não vegetadas	6	-	21	1	1	7	36
Floresta Aberta	3	-	1	171	34	2	211
Floresta Densa	8	-	-	25	86	1	120
Savana	37	-	6	29	-	106	178
Total	153	3	30	252	121	128	687

A matriz de confusão mostra que 486 *pixels* de um total de 687 se mostraram concordantes com os resultados oriundos da classificação, o que representa uma exatidão global de 74,09%, *Kappa* de 64,60%, considerado muito bom, e *Tau* de 68,90%. A classificação de Landis e Koch (1977), proposta para o índice *Kappa*, ao se considerar para os valores do *Kappa* condicional, o dado com correção atmosférica a partir do QUAC demonstrou-se excelente para as classes água e áreas não vegetadas, muito boa para a floresta densa, savana e agropecuária, e boa para a floresta aberta. Não houveram classes consideradas razoável, ruim ou péssima sob o ponto de vista do *Kappa* condicional, o que demonstra o melhor desempenho dessa classificação em comparação ao dado sem correção atmosférica.

A classe água apresentou nível de concordância de 100% com a classificação, tanto sob a perspectiva do produtor como do usuário, o que resultou em erros de comissão e omissão nulos para a classe. No entanto, não é possível apontar qual a classe apresentou o pior resultado, uma vez que houveram grandes variações em termos dos valores de exatidão do produtor e do usuário, e seus respectivos erros de omissão e comissão. De modo geral, de todas as classificações avaliadas e comparadas, essa foi a que apresentou menores erros, não tendo nenhuma classe apresentado erro superior a 45%, nem de omissão, nem de comissão.

Dentre as classes de vegetação, os *pixels* de referência que foram classificados corretamente, ou seja, que apresentaram maior exatidão do produtor foram os correspondentes às classes savana, floresta densa e floresta aberta, respectivamente, com 82,81%, 71,07% e 67,85%. Já as classes que apresentaram maior exatidão do usuário foram a floresta aberta, com 81,04%, floresta densa, com 71,66% e savana, com 59,55%. Comparando com a classificação sem correção atmosférica, percebe-se uma diminuição da representatividade da floresta aberta para a carta nesta classificação.

A classe referente às áreas não vegetadas apresentou exatidão do produtor de 70%, com erro de omissão de 30% associado. Já a exatidão do usuário foi mais baixa, sendo de 58,33%. Isso se deve ao fato de, dos *pixels* restantes, boa parte ter sido considerado savana, classe responsável em maior escala pelo erro de comissão de 41,66%, o maior observado dentre as classes. A classe agropecuária apresentou exatidões do produtor e do usuário de 64,70% e 71,22%, respectivamente.

Classificação da Cobertura do Solo com correção a partir do FLAASH

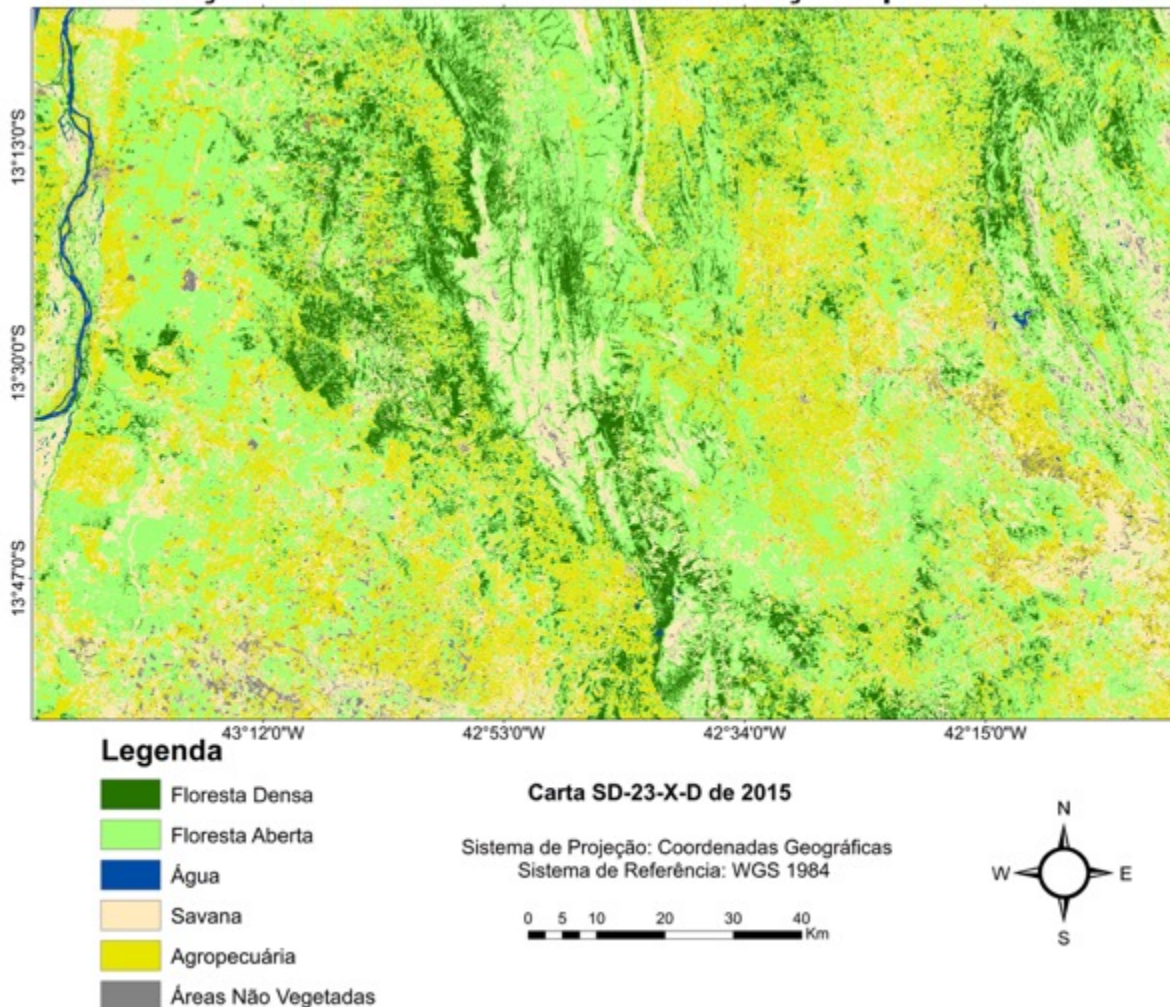


Figura 28 - Mapa da Classificação da Cobertura do Solo do Mosaico Temporal da Carta SD-23-X-D de 2015 a partir do dado com correção atmosférica a partir do FLAASH

A classificação da cobertura do solo a partir do dado em reflectância de superfície gerado pelo FLAASH diminui a presença de floresta densa e aumenta a presença de áreas de agropecuária em comparação com o dado corrigido pelo QUAC, muito embora o predomínio de áreas vegetadas se mantenha na carta, havendo apenas certa confusão espectral entre as referidas classes ao se comparar os três métodos. As áreas não vegetadas diminuíram em comparação com o dado corrigido pelo QUAC, mostrando padrão visual mais similar à classificação a partir de dados TOA para essa classe. A água, assim como os outros resultados, foi bem classificada. A Tabela 21 apresenta a matriz de confusão para a classificação da carta SD-23-X-D do ano de 2015 a partir de dados corrigidos pelo FLAASH.

Tabela 21 - Matriz de Confusão da classificação oriunda a partir dos dados de reflectância de superfície gerados pelo FLAASH

Referência (Verdade) \ Classificação	Agropecuária	Água	Áreas não vegetadas	Floresta Aberta	Floresta Densa	Savana	Total
Agropecuária	124	-	5	10	-	19	158
Água	-	3	-	-	-	-	3
Áreas não vegetadas	1	-	15	-	-	-	16
Floresta Aberta	13	-	1	212	58	15	299
Floresta Densa	7	-	-	7	62	1	77
Savana	8	-	9	23	1	93	134
Total	153	3	30	252	121	128	687

A matriz de confusão permite constatar que um total de 509 *pixels* concordaram entre si em relação à totalidade dos pontos considerados como referência. Isso representa uma exatidão global de 74,09%, *Kappa* de 64,60%, considerado muito bom, e *Tau* de 68,90%. Considerando a escala de qualidade de Landis e Koch (1977) para cada classe individualmente aplicada aos valores do *Kappa* condicional, o dado corrigido pelo FLAASH pode ser considerado excelente para as classes água e áreas não vegetadas, muito boa para a agropecuária, floresta densa e savana, e boa para a floresta aberta. O conjunto de dados informados nesse parágrafo já são suficientes para apontar o dado corrigido pelo FLAASH como sendo o que apresentou melhor desempenho para a carta SD-23-X-D, do ano de 2015.

A água apresentou alto nível de concordância, tanto sob a perspectiva do produtor como do usuário, sendo de 100% de exatidão para ambos. Assim como no dado corrigido pelo QUAC para a mesma carta, não houve uma classe que tenha se destacado por apresentar os piores resultados. Em termos de exatidão do produtor, com exceção das classes floresta densa e áreas não vegetadas, todas as classes apresentaram valores de exatidão superiores a 70%. O mesmo ocorreu para a exatidão do usuário, porém não sendo observados erros de comissão maiores que 30% para nenhuma das seis classes.

Dentre as classes de vegetação, a que apresentou melhores resultados foi a floresta aberta, com exatidão do produtor de 84,12% e do usuário de 70,90%, seguida da classe savana, com 72,65% e 69,40% e floresta densa, com 51,23% e

80,51% para as exatidões do produtor e usuário, respectivamente. A classe floresta densa, inclusive, se confundiu muito com a classe floresta aberta.

A classe correspondente às áreas não vegetadas, por sua vez, apresentou resultados muito favoráveis sob a perspectiva da exatidão do usuário, com 93,75%. Já para a exatidão do produtor, apresentou 50% de concordância, o que mostra que vários *pixels* foram atribuídos a classes que não pertencem na realidade, como por exemplo, da classe savana. Entretanto, assim como já foi dito, essa classe não apresentou muitos pontos amostrais, o que mostra sua baixa predominância na carta. Os erros de omissão e comissão para a classe agropecuária, foram, respectivamente, 18,95% e 21,51%, ou seja, de um modo geral é possível afirmar que a classe foi bem representada no sentido de que maior parte dos seus *pixels* foram classificados adequadamente.

4.3 Comparação entre os resultados obtidos a partir dos coeficientes de concordância globais e por classe

A Tabela 22 apresenta uma síntese dos resultados estatísticos a partir do uso dos índices de concordância globais para as classificações baseadas nos três diferentes dados de reflectância utilizados para avaliar cada uma das duas cartas. A partir das informações observadas na tabela e já previamente analisadas separadamente para cada carta, é possível constatar que ambas apresentaram melhores resultados em termos globais para as classificações cujos dados foram submetidos à correção atmosférica. Entretanto, enquanto a carta SC-24-V-C apresentou melhores resultados para o dado corrigido pelo QUAC, a carta SD-23-X-D indicou uma melhor performance da classificação a partir dos dados corrigidos pelo FLAASH. Os três índices utilizados, apesar de variarem os valores entre si não apresentam divergências quanto ao resultado apontado.

As diferenças encontradas entre a exatidão global e o índice *Kappa* é normal (FERREIRA et al., 2005; MATHER, 2004), visto que o segundo resume a informação proveniente da matriz de erro; enquanto o primeiro é a média da acurácia individual das classes. Brites (1995) afirma que na formulação do índice *Tau*, o valor da concordância casual é estabelecido *a priori*, evitando falhas que incorrem da exatidão global e do índice *Kappa*. Isso faz com que o *Tau*, de acordo com o autor,

talvez seja o índice que represente com maior fidedignidade a exatidão dos processos de classificação.

Tabela 22 - Coeficientes de concordância globais para cada método calculados para cada carta da Caatinga

	SC-24-V-C			SD-23-X-D		
	FLAASH	QUAC	TOA	FLAASH	QUAC	TOA
Exatidão Global	49,28%	65,08%	61,78%	74,09%	70,74%	62,88%
Kappa	34,08%	52,97%	49,24%	64,60%	61,55%	48,28%
Tau	39,13%	58,10%	54,13%	68,90%	64,89%	55,45%

Se for feita uma análise isolada para cada carta a partir do coeficiente *Kappa* é possível verificar que se associarmos os valores obtidos com a avaliação do índice proposta por Landis e Koch (1977) para a carta SC-24-V-C, a classificação que apresentou melhor performance (QUAC) é considerada boa, pois se encontra no intervalo entre 40% e 60%. Já para a carta SD-23-X-D, as duas classificações oriundas de dados com correção atmosférica (FLAASH e QUAC) são consideradas muito boas, pois seus resultados para o índice se encontram no intervalo entre 60% e 80%.

Analisando as classificações pelos dados de reflectância utilizados, verifica-se que os dados corrigidos pelo QUAC apresentaram uma performance considerável, uma vez que geraram os melhores resultados para a carta SC-24-V-C, enquanto que para a carta SD-23-X-D variaram entre 3% e 4% comparados aos dados corrigidos pelo FLAASH (melhor para a carta) para os três coeficientes de concordância. Isso representa uma grande vantagem para o método, considerando sua maior praticidade (de onde infere-se maior rapidez) e menor complexidade para corrigir os efeitos atmosféricos.

Em ambas as cartas os valores das classificações geradas a partir de dados de reflectância no topo da atmosfera apresentaram uma similaridade muito elevada comparando os três índices de concordância. Isso acaba fornecendo ao dado certa consistência em termos de classificação, o que acaba sendo uma vantagem a se levar em consideração, já que as imagens classificadas se tratam de mosaicos com cenas provenientes de datas diferentes de um bioma cuja sazonalidade pode

representar um aspecto um tanto problemático na geração de classificações da cobertura do solo. Entretanto, seria altamente recomendável o uso de *endmembers* que melhor representassem as diferentes classes de vegetação, além de possíveis ajustes na árvore de decisão.

De um modo geral, a análise sistêmica das diferentes classificações por meio do uso dos coeficientes de concordância global contribui, sem qualquer dúvida, para que seja possível chegar a diferentes conclusões sobre o impacto da correção atmosférica na classificação da cobertura do solo na Caatinga. No entanto, para que se tenha um panorama ainda melhor acerca do desempenho dessas classificações, uma análise mais detalhada por meio dos coeficientes de concordância por classe faz-se necessária, pois assim é possível identificar por exemplo, as classes que apresentam maior confusão entre si e aquelas que podem impactar em diferentes intensidades as diferentes classificações. Assim, as Tabelas 23 e 24 apresentam os resultados das exatidões do produtor e do usuário para cada classe de cada carta avaliada. Enquanto a exatidão do produtor indica a probabilidade de acerto da classificação (erro de omissão), a exatidão do usuário indica a probabilidade de um *pixel* classificado na imagem de fato corresponder com o dado de referência (verdade de campo), sendo, assim, está associada ao erro de comissão.

Tabela 23 - Exatidão do Produtor de cada classe dos métodos de classificação de cada carta

CLASSES	SC-24-V-C			SD-23-X-D		
	FLAASH	QUAC	TOA	FLAASH	QUAC	TOA
Agropecuária	0,29	-	0,25	0,81	0,64	0,29
Água	1	1	1	1	1	1
Áreas não vegetadas	0,95	0,87	0,95	0,50	0,70	0,23
Savana	0,33	0,64	0,26	0,72	0,82	0,60
Floresta Aberta	0,27	0,52	0,70	0,84	0,67	0,92
Floresta Densa	-	0,16	-	0,51	0,71	0,56

Para todos os métodos em ambas as cartas avaliadas, a água foi a classe que apresentou melhor desempenho, com 100% de exatidão do produtor. As demais classes variaram bastante em função do dado de reflectância utilizado e também em função da carta, o que pode ser um forte indício de que fatores, tais como condições climáticas e disposição da paisagem possam ter interferido de maneira considerável

nos resultados observados. A floresta densa apresentou o pior resultado considerando todos os métodos para ambas as cartas. Entretanto, na carta SC-24-V-C, os valores praticamente nulos para os métodos podem representar um forte indício de ausência da classe, fato esse que é bastante evidente ao se observar o mapa de referência do MMA. O mesmo mapa para a carta SD-23-X-D mostra maior presença dessa classe, o que é refletido nos dados de exatidão apresentados.

Observando os resultados para a carta SC-24-V-C, verifica-se que as áreas não vegetadas apresentaram valores de exatidão do produtor bastante elevados, o que reforça a probabilidade de acerto da classificação para esta classe. Além disso, é possível detectar a classe que contribuiu para uma menor exatidão global para a carta para a classificação gerada a partir de dados FLAASH: a floresta aberta. Os resultados de exatidão do produtor oriundos dos dados FLAASH para todas as classes são muito semelhantes se comparados com os do dado TOA. Porém, este último apresentou uma exatidão muito maior para a classe floresta aberta.

Verificando as duas cartas, de modo geral, as exatidões do produtor foram maiores para a carta SD-23-X-D. Porém a única classe, além da água, que apresentou bons resultados foi a referente às áreas não vegetadas. Isso reforça a ideia de impacto da seca nessa classificação, que pode ter contribuído para uma superestimação dessa classe em detrimento da classe savana e até mesmo para a floresta aberta, que ao apresentarem vegetações com aspecto seco e um maior espaçamento entre si, faz com que boa informação do *pixel* seja de um aspecto similar ao solo exposto, gerando a confusão. Isso não ocorreu na outra carta, onde classes de vegetações apresentaram exatidões até maiores.

Tabela 24 - Exatidão do Usuário de cada classe dos métodos de classificação de cada carta

CLASSES	SC-24-V-C			SD-23-X-D		
	FLAASH	QUAC	TOA	FLAASH	QUAC	TOA
Agropecuária	-	-	0,42	0,78	0,71	0,75
Água	0,98	0,94	1	1	1	0,75
Áreas não vegetadas	0,38	0,55	0,43	0,93	0,58	0,50
Savana	0,39	0,53	0,65	0,69	0,59	0,51
Floresta Aberta	0,81	0,87	0,75	0,70	0,81	0,62
Floresta Densa	-	0,25	-	0,80	0,71	0,80

Os resultados de exatidão do usuário também foram bastante elevados para a água, com uma única exceção no dado em reflectância no topo da atmosfera da carta SD-23-X-D, que ficou em 75%. A classe de agropecuária, em contrapartida, teve exatidão entre alguns pontos apenas nesse dado para a carta SC-24-V-C. Já para a carta SD-23-X-D pode-se dizer que a classe foi igualmente classificada, não havendo diferenças muito significativas.

Para a carta SC-24-V-C, depois da água, a classe que melhor foi representada sob o ponto de vista da exatidão do usuário nas três classificações foi a floresta aberta, com destaque para o QUAC, com 87%. O dado corrigido por esse método foi o único que demonstrou alguma probabilidade de *pixels* da classe floresta densa de fato corresponderem com o dado de referência, uma vez que os dois métodos apresentaram ausência de resultados para a classe. Para a carta o método também demonstrou a maior exatidão do usuário para a classe áreas não vegetadas, com 55%. A correção pelo FLAASH não superou nenhum método para nenhuma classe em termos de apresentar maiores probabilidades de concordância com os dados de referência, fato esse que concorda com os resultados mostrados pelos coeficientes de concordância global, onde o FLAASH demonstrou ser o menos apropriado para classificar a carta.

No contexto da carta SD-23-X-D a classificação gerada a partir de dados corrigidos pelo FLAASH apresentou maiores probabilidades de concordância entre os *pixels* para todas as classes, com exceção da floresta aberta, que apresentou exatidão do usuário de 70% contra 81% do dado corrigido pelo QUAC. Entretanto, as diferenças entre ambos os dados que foram submetidos à correção atmosférica não são tão relevantes em comparação aos dados de reflectância aparente, ou seja, sem correção atmosférica.

Tabela 25 - *Kappa* Condicional de cada classe dos métodos de classificação de cada carta

CLASSES	SC-24-V-C			SD-23-X-D		
	FLAASH	QUAC	TOA	FLAASH	QUAC	TOA
Agropecuária	-	-	0,41	0,72	0,63	0,68
Água	0,98	0,94	1	1	1	0,75
Áreas não vegetadas	0,23	0,44	0,29	0,93	0,56	0,48
Savana	0,12	0,33	0,50	0,62	0,50	0,40
Floresta Aberta	0,72	0,81	0,63	0,54	0,70	0,40

Floresta Densa	-	0,24	-	0,76	0,66	0,76
-----------------------	---	------	---	------	------	------

Fazendo uma avaliação mais apurada do *Kappa* condicional para a carta SC-24-V-C constata-se que o dado corrigido pelo QUAC, de fato, apresentou os valores mais elevados para a maioria das classes em comparação aos outros dados de reflectância, apresentando o menor valor apenas para a água (ainda que considerado excelente). Entretanto, para as classes agropecuária e savana, o dado TOA demonstrou melhores resultados na referida carta. Para a carta SD-23-X-D, o dado corrigido pelo FLAASH apresentou resultados superiores para todas as classes, com exceção da classe floresta aberta, cujo resultado para o coeficiente foi melhor no dado corrigido pelo QUAC.

Considerando a avaliação de Landis e Koch (1977) para o coeficiente *Kappa* condicional para a carta SC-24-V-C, o resultado para a água foi excelente nas três classificações, muito bom para a floresta aberta nos dados com a atmosfera corrigida, bom para as classes agropecuária e savana apenas no dado sem correção atmosférica, e para as áreas não vegetadas no dado corrigido pelo QUAC. Para a classe floresta densa, o maior resultado seria considerado razoável, resultante também do dado corrigido pelo QUAC.

Fazendo a mesma análise do parágrafo anterior para a carta SD-23-X-D os melhores resultados observados para cada classe em função das classificações geradas foram excelente para a água nos dois métodos com correção atmosférica, e para as áreas não vegetadas no método corrigido pelo FLAASH, muito bom para as classes agropecuária e floresta densa nos três dados de reflectância, enquanto que para a savana foi muito bom apenas no dado corrigido pelo FLAASH enquanto que para a floresta aberta no dado corrigido pelo QUAC.

Observando os resultados dos três coeficientes de concordância para cada classe individualmente, é possível concluir o impacto dos dados com e sem correção atmosférica em cada classe de cada carta. Para a carta SC-24-V-C, as áreas de agropecuária foram melhor classificadas pelo dado sem correção atmosférica, mesmo tendo apresentado níveis de concordância menores que 50% para os três coeficientes utilizados. A água foi classificada com alto nível de exatidão, e apresentou valores superiores a 90% para os três coeficientes, tendo o dado sem correção atmosférica classificado com 100% de exatidão. Já dentre os dados com a

atmosfera corrigida, o FLAASH apresentou-se sutilmente melhor, tendo variado de 98% a 100% de exatidão.

Os *pixels* correspondentes às áreas não vegetadas se confundiram bastante, apresentando-se ora melhores para um coeficiente, ora para o outro em cada dado. Sob a ótica da exatidão do produtor, o dado sem correção atmosférica apresentou-se excelente na classificação, ou seja, 95%. Entretanto, sob a ótica dos outros dois índices apresentou melhor resultado para o dado corrigido pelo QUAC, com 44% para ambos. Isso requer uma investigação mais detalhada para descobrir os fatores que de fato podem ter influenciado esse comportamento. Comportamento semelhante foi observado para a classe floresta aberta.

A classe savana apresentou comportamento inverso, com melhor performance do dado corrigido pelo QUAC sob a ótica da exatidão do produtor e melhores resultados para o dado sem correção atmosférica para os outros dois índices. Por fim, para essa carta a classe floresta densa apresentou resultados muito baixos para todos os coeficientes utilizados, mas o único dado que apresentou resultado diferente de zero para os três foi o submetido à correção da atmosfera pelo QUAC.

Para a carta SD-23-X-D, o dado corrigido pelo FLAASH apresentou melhores resultados para a classe agropecuária, apresentando resultados superiores a 70% para todos os três coeficientes de concordância. A classe água apresentou 100% de exatidão para ambos os dados com correção atmosférica para os três coeficientes. A classe que equivale às áreas não vegetadas apresentou maior exatidão para os dados submetidos à correção atmosférica, superando 90% para o FLAASH sob a ótica da exatidão do usuário e do *Kappa* condicional, porém, com maior exatidão do produtor registrada pelo QUAC, com 70%. Comportamento similar foi observado para a classe savana.

A floresta aberta foi a única com maior exatidão observada para um dos coeficientes para o dado sem correção atmosférica, com 92% de exatidão do produtor. Entretanto, para os demais coeficientes apresentou melhores resultados para o dado corrigido pelo QUAC. A classe floresta densa teve bastante equivalência entre os índices para todos os dados, tendo apresentado similaridades entre dados com e sem correção atmosférica. Porém, comparando a exatidão da classe sob a ótica dos três coeficientes, o dado com correção atmosférica

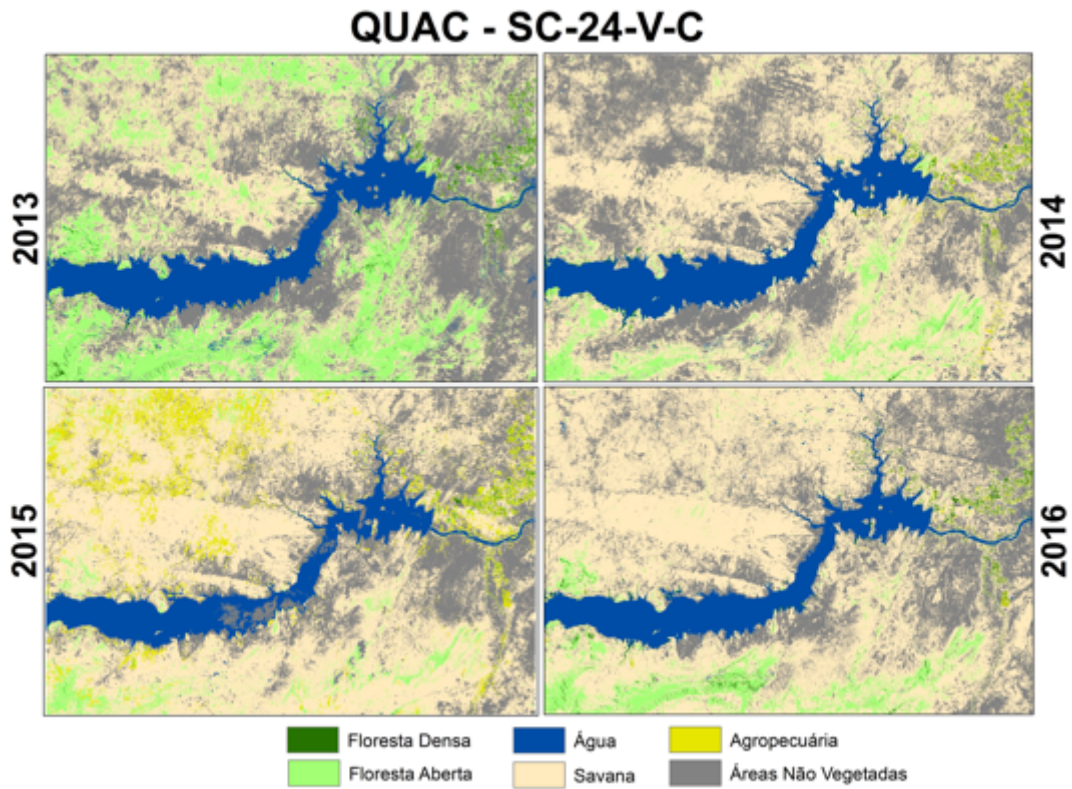


Figura 30 - Evolução temporal (2013-2016) do dado QUAC da carta SC-24-V-C.

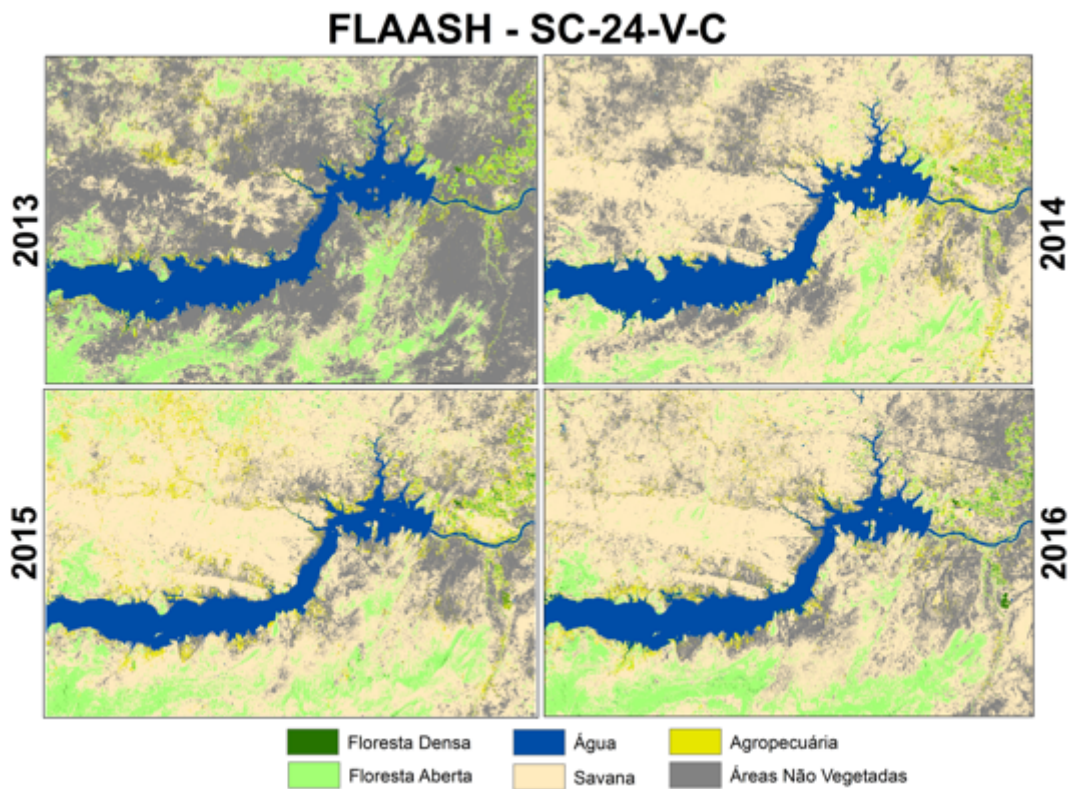


Figura 31 - Evolução temporal (2013-2016) do dado FLAASH da carta SC-24-V-C.

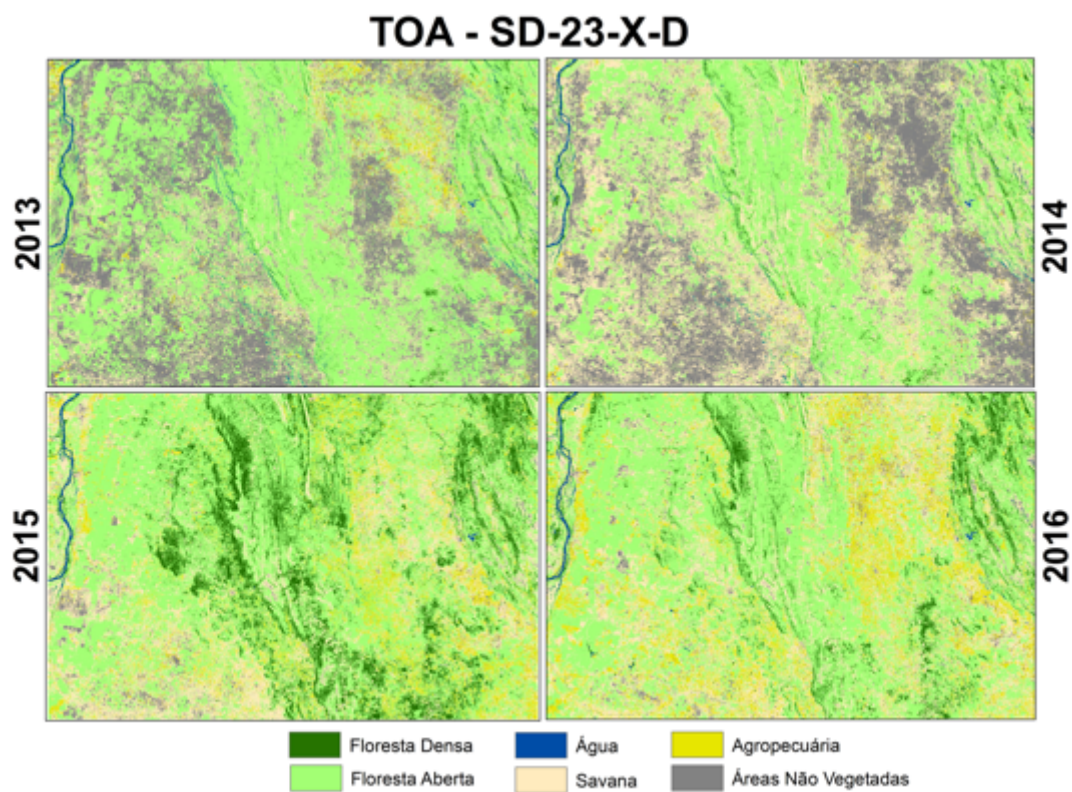


Figura 32 - Evolução temporal (2013-2016) do dado TOA (topo da atmosfera) da carta SD-23-X-D.

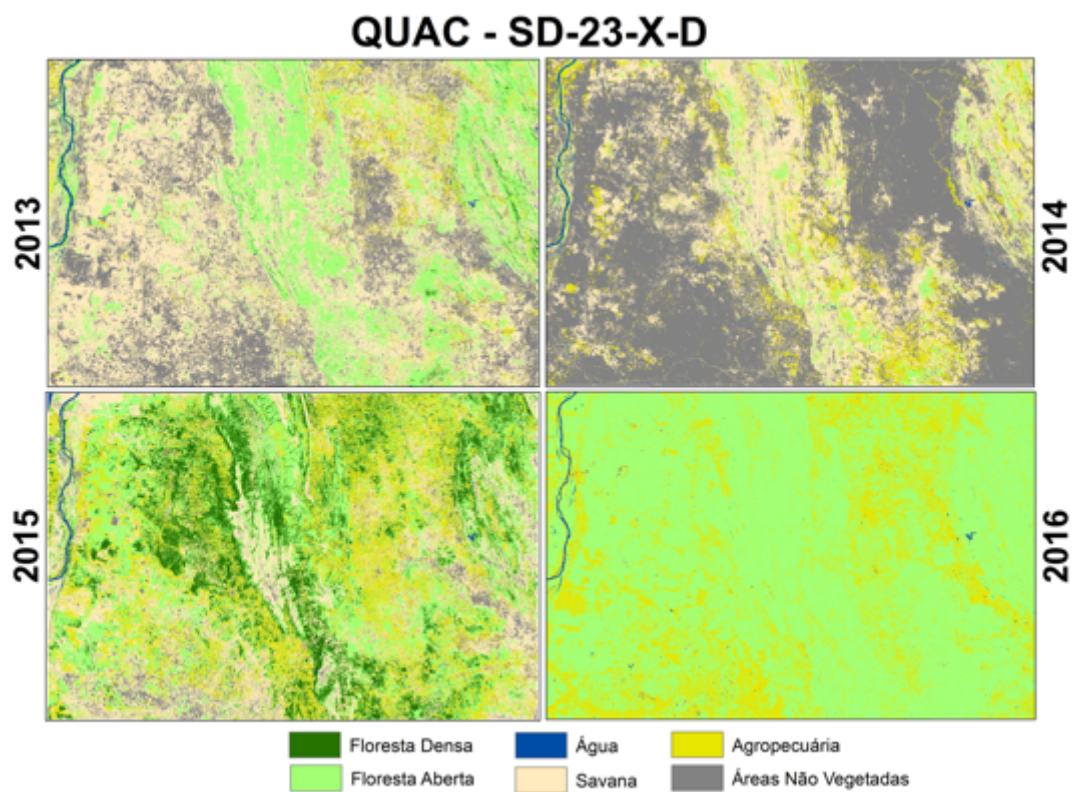


Figura 33 - Evolução temporal (2013-2016) do dado QUAC da carta SD-23-X-D.

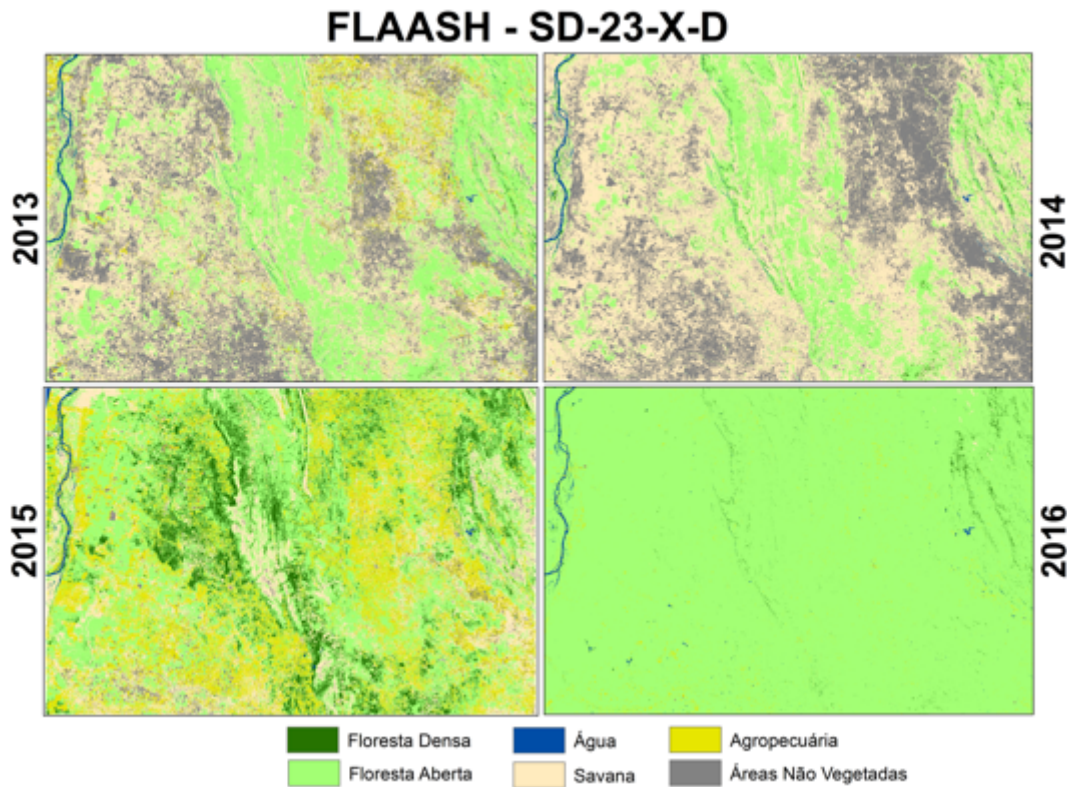


Figura 34 - Evolução temporal (2013-2016) do dado FLAASH da carta SD-23-X-D.

Fazendo uma verificação do predomínio de cada classe em função do método de classificação, para os dados que sofreram correção atmosférica por meio do FLAASH, a classe savana mostrou-se predominante na carta SC-24-V-C em todos os anos, com exceção de 2013, onde a classe referente às áreas não vegetadas apresentou maior influência. Na carta SD-23-X-D, por sua vez, a classe savana foi a mais abrangente nos anos de 2013 e 2014, enquanto que a classe floresta aberta prevaleceu em 2015 e 2016. Já partindo para a correção atmosférica por meio do QUAC, para a carta SC-24-V-C a classe savana predominou em todos os anos. Já para a carta SD-23-X-D, nos anos de 2013 e 2015 houve uma prevalência da classe savana. Em 2014, da classe correspondente às áreas não vegetadas e em 2016 da classe floresta aberta. Por fim, avaliando as classificações oriunda do dado em reflectância TOA, observou-se a predominância das seguintes classes para os seguintes anos: para a carta SC-24-V-C, áreas não vegetadas em 2013, savana em 2014 e 2016, floresta aberta em 2015; e para a carta SD-23-X-D, floresta aberta para os anos 2013, 2014 e 2015 e savana para o ano de 2016. Essa variação pode estar intrinsecamente ligada ao forte impacto da variabilidade sazonal no bioma.

Na região semiárida prevalecem duas estações, uma seca e outra chuvosa durante o ano. Dessa forma, há um período em que a vegetação se encontra verde, densa, coberta de folhas, com elevada biomassa e outro em que se encontra praticamente seca, sem folhas, baixa biomassa e teor de água incipiente. Assim, conforme salientado por Batista (2011) e que pode explicar o porquê da variação do predomínio das classes descritas no parágrafo anterior é o fato das características espectrais da vegetação da Caatinga apresentarem comportamento com elevada variabilidade sazonal, o qual deve ser considerado no mapeamento da cobertura do solo a partir da análise de imagens de satélite que possibilitam estimar o comportamento espectral da vegetação, uma vez que este pode apresentar resultados mais significativos no decorrer do mesmo ano do que em um longo período temporal. Considerando que os mosaicos contêm informações de uma janela temporal de 6 meses, esse fator pode realmente estar influenciado consideravelmente nesse sentido.

Galletti e Myint (2014) ao fazerem o mapeamento da cobertura do solo em um contexto similar ao da Caatinga, uma região árida no Arizona, alegaram que a confusão espectral é um aspecto inevitável, especialmente em classes como áreas agrícolas exploradas, que são facilmente confundidas com áreas com aspecto desértico, solo exposto ou ainda áreas rurais pouco povoadas. Além disso, Sano et al. (2007) também alegaram o fato de a confusão espectral entre certas classes vegetais serem grandes desafios no mapeamento temático para o bioma Cerrado, o qual também apresenta certa similaridade com a Caatinga. Os autores também destacaram a sazonalidade marcante da vegetação natural como sendo outro fator que exerce grande influência no processo de mapeamento do bioma.

Observando todas as classificações ao longo dos anos, ambos os dados de reflectância aparente e de superfície, para o ano de 2013, mostram um padrão de áreas não vegetadas bastante evidente em comparação anos demais anos. Isso é uma demonstração clara do impacto da sazonalidade na classificação da cobertura do solo na região, uma vez que o ano de 2013 registrou a maior seca dos últimos 50 anos que o antecederam, conforme relatório “Declaração sobre o Estado do Clima”, divulgado pela Organização Meteorológica Mundial, agência das Nações Unidas especializada em monitorar eventos climáticos (WMO, 2014). O evento foi tão forte que resultou na morte de cerca de 4 milhões de animais, além da baixa dos reservatórios de água das hidrelétricas na região. Esse mesmo evento de seca se

estendeu para parte do ano de 2014, o que também é evidente nas cartas, uma vez que o intervalo temporal considerado para a geração dos mosaicos compreende o primeiro semestre de cada ano.

Em termos espectrais, a classificação da cobertura do solo é fortemente impactada por eventos dessa natureza, independentemente da correção ou não da atmosfera para os dados, muito embora uma diferença tenha ficado bastante clara ao se observar as imagens para ambas as cartas: os dados com correção atmosférica conseguiram diferenciar melhor áreas não vegetadas de áreas savânicas, o que não ocorreu para o dado sem correção atmosférica (TOA). Isso mostra que em contexto de seca, o dado com correção atmosférica mostra maior eficiência na distinção de alvos intrínsecos ao contexto do semiárido, mesmo considerando os erros de omissão e comissão associados às classes. O ano de 2013 foi avaliado em termos estatísticos para a carta SC-24-V-C e mostrou melhores resultados do QUAC. Além disso, para a carta SD-23-X-D nota-se uma semelhança muito grande entre as classificações oriundas dos dados corrigidos pelo QUAC e FLAASH, enquanto a classe referente à savana foi subestimada pelo dado TOA, onde percebeu-se um leve aumento de áreas não vegetadas.

Ainda sob uma perspectiva climática, outro aspecto que merece ser abordado é quanto à influência dos fenômenos El Niño e La Niña na classificação da cobertura do solo em ambientes semiáridos. De acordo com dados do NOAA (2017), os anos de 2013 e 2014 não sofreram interferência de nenhum dos fenômenos. O ano de 2015 foi marcado pela manifestação do fenômeno El Niño em uma de suas maiores intensidades em décadas que o antecederam. Esse evento também se prolongou ao longo do primeiro semestre de 2016. A influência desses fenômenos no comportamento das classificações deve ser melhor avaliada, porém, o ano de 2016 apresentou superestimação das classes de vegetação para os dados corrigidos pelo FLAASH e QUAC, o que pode ou não ter exercido algum tipo de impacto nos resultados observados. Em 2015, as classes áreas não vegetadas e savana ficaram em evidência na carta SC-24-V-C, enquanto as áreas de agricultura aumentaram na carta SD-23-X-D para o mesmo ano nos dados em reflectância de superfície. Isso pode reforçar a tendência de esses eventos causarem um maior impacto nos dados em reflectância de superfície.

Ainda considerando o que foi observado em 2016 para os dados corrigidos pelo FLAASH e QUAC para a carta SD-23-X-D, um fato merece destaque quanto ao

desempenho do FLAASH: o parâmetro visibilidade, o qual foi considerado abaixo de 40 km, indicando uma atmosfera turva, nebulosa. Conforme foi visto, esse parâmetro é levado em consideração caso não sejam identificados *pixels* escuros na imagem. Ainda assim, o FLAASH estima uma visibilidade e fornece como resultado após proceder com a correção atmosférica. A Tabela 26 apresenta os valores calculados para a visibilidade e colocados antes de processar o FLAASH e os resultados obtidos como resultado após a correção atmosférica. Além disso, a tabela também mostra se houve a recuperação de aerossóis, que por sua vez não ocorreu para nenhuma carta processada.

Tabela 26 - Parâmetros de visibilidade utilizados como dado de entrada antes de proceder o FLAASH e resultado após correção atmosférica

Carta_Ano	Visibilidade (input) (km)	Visibilidade (output) (km)	Recuperação de Aerossol?
SC-24-V-C_2013	36,31	162,17	Não
SC-24-V-C_2014	40,12	194,02	Não
SC-24-V-C_2015	23,90	227,73	Não
SC-24-V-C_2016	30,56	168,40	Não
SD-23-X-D_2013	30,23	300,00	Não
SD-23-X-D_2014	41,18	300,00	Não
SD-23-X-D_2015	18,54	300,00	Não
SD-23-X-D_2016	17,20	20,56	Não

Conforme é possível perceber, apesar da maioria dos anos ter resultado em visibilidades menores que 40 km no dado de entrada do FLAASH, todos os anos processados para ambas as cartas, com exceção do ano de 2016 para a carta SD-23-X-D, tiveram visibilidades consideradas elevadas, de onde infere-se uma atmosfera clara, visível. Para a carta SD-23-X-D, a qual apresentou resultado de 20,56 km, a visibilidade mostrou-se como um dos fatores possivelmente afetou no resultado obtido para a carta em questão. Além disso, Shiwei et al. (2016) afirmam que visibilidades entre 20 e 30 km são consideradas como nebulosidade moderada, o que pode explicar o impacto exercido no dado em reflectância de superfície resultante do FLAASH. Além disso, apesar de o parâmetro visibilidade não ser considerado pelo QUAC, foi possível observar um comportamento muito similar de superestimação da classe floresta aberta em quase toda a dimensão da carta, o que pode denotar certa influência das condições atmosféricas do mosaico. Ainda

conforme destacado por Latorre et al. (2002) o uso do FLAASH para correção de imagens, apesar de ser muito conhecido, nem sempre se demonstra satisfatório para a correção de algumas variáveis tais como visibilidade e quantidade de vapor d'água na atmosfera, uma vez que o algoritmo perde a precisão por utilizar modelos empíricos, podendo apresentar ruído em determinadas superfícies.

Uma comparação maior e mais detalhada dos dados permite verificar que o dado de reflectância no topo da atmosfera, apesar de ter apresentado menor resultado estatístico em uma das cartas, não é um dado que mereça ser descartado. Trata-se de um dado que apresentou maior consistência entre as análises para as duas cartas avaliadas, mantendo seus resultados estatísticos praticamente iguais para ambas as cartas. Além disso, o fato das cartas possuírem padrões de cobertura do solo diferentes, com maior predominância de algumas classes em detrimento de outras, e considerando ainda, dada a janela temporal definida para o estudo, que o mosaico temporal carrega inevitavelmente consigo características do período de seca, configuram-se como argumentos suficientes para embasar as vantagens do dado, muito embora seja importante deixar claro a necessidade de ajustes nos *endmembers* e/ou nos nós da árvore de decisão, a fim de se obter um dado com melhores resultados.

Uma prova de que o dado em reflectância no topo da atmosfera mereça ser considerado é destacado no estudo desenvolvido por Carvalho e Baptista (2015), por meio do qual verificou-se que o dado sem correção atmosférica forneceu melhores resultados em comparação com o mesmo dado após ser submetido à correção atmosférica pelo FLAASH, fato esse que reforça o que foi dito no parágrafo anterior, tendo em vista que o estudo desenvolvido pelos autores se deu em uma área do bioma Cerrado, o qual possui maior semelhança com a Caatinga dentre os demais biomas brasileiros. Os autores apontaram ainda a correção atmosférica como sendo dispensável para o caso avaliado.

Um outro fator que certamente exerce um certo impacto nos resultados das classificações dessa natureza é a resolução do Landsat. Considerando-se que um *pixel* de 30 metros compreende uma quantidade relativa de informação, muitas vezes um *pixel* que está localizado em uma zona de transição, por exemplo, entre uma faixa encoberta por vegetação e uma área não vegetada, acabará sendo vinculado à classe que maior prevalecer nas dimensões desse *pixel*. Considerando que os pontos amostrais não compreendem toda a dimensão do *pixel*, o processo de

avaliação estatística também acaba inevitavelmente vindo com erros associados, uma vez que representa a realidade sob uma perspectiva mais abrangente e não muito específica. Dado o amplo espaçamento que uma área considerada vegetada pode ter em termos de distribuição de espécies arbóreas, um determinado *pixel* da resolução do Landsat-8 (30 metros) tende a contribuir para o erro no resultado final da classificação.

5 CONCLUSÕES E SUGESTÕES

Como foi visto neste trabalho, o uso de dados com e sem correção atmosférica para a classificação da cobertura do solo no bioma Caatinga apresentou comportamentos bastante peculiares. De um modo geral, o dado com correção atmosférica representou melhor a realidade do bioma em ambas as cartas avaliadas, sendo que na carta SC-24-V-C os dados corrigidos pelo QUAC apresentaram melhores resultados em termos estatísticos, enquanto na carta SD-23-X-D, os resultados corrigidos pelo FLAASH se mostraram melhores. Avaliando pelo índice *Tau*, a diferença entre ambos os métodos foi de 19% para a carta SC-24-V-C e de 4% para a carta SD-23-X-D.

Porém, se for considerado o fato de o FLAASH ter apresentado melhor e pior desempenho para as avaliações feitas nas cartas SD-23-X-D e SC-24-V-C, respectivamente, isso faz com que esse dado não seja muito apropriado para análises na Caatinga, dada a inconsistência de seus resultados e complexidade no processo de execução em comparação com o QUAC. Tomando por base o fato de a Caatinga ser coberta por 68 cartas, e considerando ainda que cada carta exigiria o preenchimento de parâmetros específicos para executar o FLAASH em cada ano mapeado, também são fatores que tornam esse algoritmo dispensável para o contexto do MapBiomas.

O QUAC, por sua vez, não apresenta qualquer complexidade para gerar o dado em reflectância de superfície e também apresenta vantagens no tempo de processamento. Além disso, demonstrou maior adequabilidade diante da influência da sazonalidade, dados os parâmetros utilizados pela árvore de decisão utilizada. Isso faz com que o dado corrigido pelo QUAC seja o que melhor se ajusta aos objetivos do MapBiomas.

O dado em reflectância no topo da atmosfera, por sua vez, superestimou algumas classes em detrimento de outras, não representando bem algumas classes. No entanto, um fato é importante de se destacar: a consistência estatística do dado. Enquanto para a carta SC-24-V-C o dado apresentou diferença de 4% em comparação com o dado corrigido pelo QUAC, apresentou 13% de diferença em comparação com o dado corrigido pelo FLAASH na carta SD-23-X-D e 9% de

diferença em relação ao dado corrigido pelo QUAC. Porém, os valores estatísticos obtidos para ambas as cartas nos três índices de exatidão global foi praticamente o mesmo para o dado TOA. Assim, diante da elevada consistência do dado, e ainda considerando que o produto LC8_L1T_TOA é disponibilizado no catálogo do *Google Earth Engine*, o recomendável seria fazer novos ajustes na árvore de decisão a fim de garantir melhores ajustes e uma maior adequabilidade do dado a fim de englobar todas as classes consideradas que estejam presentes nas cartas, garantindo assim uma maior fidedignidade.

Com relação à ferramenta *Google Earth Engine* conclui-se que se trata uma plataforma muito ágil e que permitiu que as classificações fossem geradas em um espaço de tempo muito mais curto em comparação com vários outros *softwares* disponíveis no mercado. Os scripts elaborados pelo MapBiomias para proceder com a classificação são muito completos e abrangem toda a rotina necessária, gerando um dado de qualidade.

Como sugestão para trabalhos futuros no âmbito do MapBiomias destaca-se o aprimoramento da árvore de decisão contemplando especificidades do bioma Caatinga, tais como o desenvolvimento de métodos mais refinados na classificação dos alvos vegetais, e a consequente realização de novos testes em relação à janela temporal definida para geração do mosaico; e o aprofundamento da análise da variação temporal interanual cruzando com dados de variação climática (El Niño/La Niña).

Além disso, outra sugestão que se mostra relevante para o contexto avaliado é a necessidade de testar outros índices de vegetação que poderiam melhor se adequar ao contexto do bioma. Isso envolve o teste de novos ajustes para o NDFI ou ainda a aplicação do índice SAVI, que considera a interferência do solo na detecção da vegetação, o que pode de repente tornar o mapeamento da Caatinga mais realista. Um fato é claro e merece atenção para novos estudos: a necessidade do desenvolvimento de um índice de vegetação voltado para contextos semiáridos, garantindo sua maior representatividade em mapeamentos que englobem diferentes classes vegetais.

REFERÊNCIAS

- AB'SÁBER, A. N. Relevô, Estrutura e Rede Hidrográfica do Brasil. **Boletim Geográfico**, 14: 255-268, 1956.
- AB'SÁBER, A. N. Os domínios morfoclimáticos da América do Sul. **Geomorfologia**, 52: 1-21, 1977
- ADAMS, J. B., SMITH, M. O., & JOHNSON, P. E. Imaging spectroscopy: Interpretation based on spectral mixture analysis. In C. M. Pieters, & P. A. J. Englert (Eds.), **Remote geochemical analysis: Elemental and mineralogical composition**. Cambridge, England: Cambridge University Press, 1993, pp. 145-164.
- ADLER-GOLDEN, S.M.; MATTHEW, M.W.; BERNSTEIN, L.S.; LEVINE, R.Y.; BERK, A.; RICHTSMIEIER, S.C.; ACHARYA, P.K.; ANDERSON, G.P.; FELDE, G.; GARDNER, J.; HIKE, M.; JEONG, L.S.; PUKALL, B.; MELLO, J.; RATKOWSKI, A.; BURKE, H. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. **SPIE Proc. Imaging Spectrometry**, v. 3753, p. 61-69, 1999.
- ALBUQUERQUE, S. G.; BANDEIRA, G. R. L. Effect of thinning and slashing on forage phytomass from a caatinga of Petrolina, Pernambuco, Brazil. **Pesquisa Agropecuária Brasileira**, v. 30, p. 885-885, 1995.
- AMERICAN SOCIETY OF PHOTOGRAMMETRY. **Manual of Photographic Interpretation**. Washington: American Society of Photogrammetry, 1952.
- ANDERSON, G. P.; WANG, J. & CHETWYND, J. H. MODTRAN3: An Update and Recent Validations Against Airborne High Resolution Interferometer Measurements. **Summaries of Fifth Annual JPL Airborne Earth Science Workshop**, JPL 95-1, Vol. 1: AVIRIS Workshop, 1995, pp. 5-8.
- ANDRADE-LIMA, D. O domínio das caatingas. **Revista Brasileira de Botânica**, v. 4, p. 149-163, 1981.
- ANGELIM, L. A. A. **Programa Levantamentos Geológicos Básicos do Brasil**. Petrolina. Folha SC-24-V-C. Estados da Bahia, Pernambuco e Piauí. Organizado por Luiz Alberto de Aquino Angelim. – Escala 1:250.000. Brasília: CPRM, 1997.
- ANGSTROM, A. On the Atmospheric Transmission of Sun Radiation and on Dust in the Air. **Geografiska Annaler**, 11: 156–166, 1929.
- ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba. 2003.
- ARIAS, H. A.; ZAMORA, R. M.; BOLAÑOS, C. V. Metodología para la corrección atmosférica de imágenes aster, rapideye, spot 2 y landsat 8 con el módulo flaash del software envi. Atmospheric correction methodology for aster, rapideye, spot 2 and

landsat 8 images with envi flaash module software. **Revista Geográfica de América Central**, v. 2, n. 53, p. 39-59, 2014.

BAPTISTA, G. M. M. **Mapeamento e quantificação da relação Caulinita/(Caulinita+Gibbsita) de solos tropicais, por meio dos dados do sensor AVIRIS (JPL/NASA)**. Tese (doutorado). Instituto de Geociências Aplicadas, Universidade de Brasília, 278 p. 2001.

BAPTISTA, G. M. M. **Processamento de Dados Hiperespectrais**. In: MENESES, P. R.; ALMEIDA, T. (Orgs.) In: *Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Brasília: CNPQ, 2012 p. 221-238.

BATISTA, J. L. O. **Detecção de mudanças da cobertura e uso do solo a partir de índices espectrais de vegetação em ambiente semiárido: enfoque para o município de Teofilândia, Bahia.** / José Luiz Oliveira Batista. – Feira de Santana: UEFS, 2011.

BARRETT, E. C.; CURTIS, L. **Introduction to environmental remote sensing**. London: Chapman & Hall. 1992.

BERGIN, M. H.; SCHWARTZ, S. E.; HALTHORE, R. N; OGREN, J. A.; HLAVKA, D. L. Comparison of aerosol optical depth inferred from surface measurements with that determined by sun photometry for cloud-free conditions at a continental U. S. site. **Journal of geophysical research**, v. 105, n. D5, p. 6807-6816, 2000.

BERK, A. et al. Exploiting MODTRAN radiation transport for atmospheric correction: The FLAASH algorithm. In: **Information Fusion, 2002. Proceedings of the Fifth International Conference on**. IEEE, 2002. p. 798-803.

BERNARDES, T.; ALVES, H.M.R.; VIEIRA, T.G.C. Classificação automática de imagens de satélite no mapeamento da região cafeeira de Patrocínio, MG. In.: **Simpósio de Pesquisa dos Cafés do Brasil**, 5, 2007, São Paulo. Anais... Minas Gerais: EPAMIG, 2005.

BERNARDES, T. **Caracterização do ambiente agrícola do Complexo Serra Negra por meio de sensoriamento remoto e sistemas de informação geográfica**. Dissertação (Mestrado). Universidade Federal de Lavras, Minas Gerais, 2006, 119p. Disponível em: <<http://www.epamig.br/geosolos/MaterialSite/Teses/Tiago/Tiagodissertacao.pdf>>. Acesso em: 20 dez. 2016.

BERNSTEIN, S. M.; ADLER-GOLDEN, R. L.; SUNDBERG, R. Y.; LEVINE, T. C.; PERKINS, A.; BERK, A.; RATKOWSKI, A.; HOKE, M. L. A new method for atmospheric correction and aerosol optical property retrieval for VIS-SWIR multi- and hyperspectral imaging sensors: QUAC (Quick atmospheric correction),” **AVIRIS Workshop 2004**, vol. 5, pp. 3549–3552, 2004.

BERNSTEIN, L. S. Quick atmospheric correction code: algorithm description and recent upgrades. **Optical engineering**, v. 51, n. 11, p. 111719-1-111719-11, 2012.

BEZERRA, M. V. C.; SILVA, B. B.; BEZERRA, B. G. Avaliação dos efeitos atmosféricos no albedo e NDVI obtidos com imagens de satélite. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 7, p. 709-717, 2011.

BICAS, H. E. A. Mensurações em ciência. **Arquivos brasileiros de oftalmologia**. v. 66, n. 4, p. 531-37, 2003.

BISHOP, Y. M.; FEINBERG, S. E. HOLLAND, P. W. **Discrete Multivariate Analysis - Theory and Practice**. Cambridge, Mass., the MIT press, 357 p., 1975.

BOUCHER, O. **Atmospheric Aerosols**. Springer Netherlands, 2015. p. 9-24.

BRITES, R.S.; SOARES, P.S.; RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificação de imagens orbitais. In: **Anais Simpósio Brasileiro de Sensoriamento Remoto**, 8, Salvador: INPE, 1996-a.

BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. Efeitos da estratégia de amostragem na exatidão reportada pelo índice de *Kappa* na classificação de imagens orbitais. In: **Anais Simpósio Brasileiro de Sensoriamento Remoto**, 8, Salvador: INPE, 1996-b.

CADENA, G. T. **Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise orientada a objeto**. [Dissertação de mestrado em ciências cartográficas, Universidade Estadual Paulista - Faculdade de Ciências e Tecnologia]. São Paulo, 2011. Disponível em: <http://www4.fct.unesp.br/pos/cartografia/docs/teses/d_cadena_gt.pdf> Acesso em: 10/12/2016.

CARVALHO JR, O. A. **Avaliação e Desenvolvimento de Métodos de Processamento de Imagens Hiperespectrais – Análise em Depósito de Níquel (Niquelândia, GO)**. Tese de doutorado, Instituto de Geociências - Universidade de Brasília; 2000.

CARVALHO, A. A.; BAPTISTA, G. M. M. Influência da correção atmosférica na conversão dos dados de radiância para reflectância para o cálculo do EVI em imagem Rapideye. **Revista Brasileira de Cartografia**, v. 67, n. 7, 2015.

CERQUEIRA JÚNIOR, J. G. **Desenvolvimento e calibração de fotômetro solar para medições da profundidade óptica por aerossóis e coluna de água precipitável**. 110f. Tese (Doutorado em Ciências Climáticas) - Centro de Ciências Exatas e da Terra, Universidade Federal do Rio Grande do Norte, Natal, 2014.

CHANDER, G.; MARKHAM, B. L.; BARSÍ, J. A. Revised Landsat-5 thematic mapper radiometric calibration. **IEEE Geoscience and remote sensing letters**, v. 4, n. 3, p. 490-494, 2007.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote sensing of environment**, v. 113, n. 5, p. 893-903, 2009.

COHEN, J. A. Coefficient of Agreement for Nominal Scales. **Educational and Measurement**. Vol XX, No 1, p. 37-46, 1960.

COLWELL, R. N. **Manual of photographic interpretation**. American Society of Photogrammetry, 1960.

COLWELL, R. N. Uses and Limitations of Multispectral Remote Sensing. In: **Proceedings of the Fourth Symposium on Remote Sensing of Environment**. Ann Arbor: Institute of Science and Technology, University of Michigan, 1966, pp. 71-100.

COLWELL, R. N. **Manual of remote sensing**. American Society of Photogrammetry, 1983.

COLWELL, R. N. History and place of photographic interpretation. **Manual of photographic interpretation**, v. 2, p. 33-48, 1997.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and applications**. Lewis Publishers, Boca Raton, 2008.

CREPANI, E. **Princípios básicos de Sensoriamento Remoto**. São José dos Campos: INPE, 1983. 45 p.

CURRAN, P. J. Imaging spectrometry – its present and future role in environmental research. In: **Imaging Spectrometry – a Tool for environmental Observations**, edited by Joachim Hill, 1995, pp. 27-59.

DESCHAMPS PY, H. M; TANRE D. Influence de l'atmosphère en télédétection des ressources terrestres. Modélisation et possibilités de correction. In: **Colloque International Signatures Spectrales d'objets en Télédétection**. Avignon. Proceedings. Versailles: Institut National de la Recherche Agronomique, 1981, 543–558.

EGLER, W. A. **Contribuição ao estudo da caatinga pernambucana**. Instituto brasileiro de geografia e estatística Conselho nacional de geografia, 1951.

EITEN, G. Brazilian Savannas. In: Huntley, B.J. e Walker, B.H. (eds.). **Ecology of tropical savannas**. Ecological Studies, New York, Spring-Verlag. 42: 25, 1982.

ENVI. **User's Guide: Atmospheric Correction Module: QUAC and FLAASH**. ESRI, 2009.

ELACHI, C.; VAN ZYL, J. **Introduction to the physics and techniques of remote sensing**. 2ª Ed. Hoboken: John Wiley & Sons, 2006.

ELS, A.; MERLO, S.; KNIGHT, J. Comparison of two Satellite Imaging Platforms for Evaluating Sand Dune Migration in the Ubari Sand Sea (Libyan Fazzan). **The International Archives of Photogrammetry, Remote Sensing and Spatial**

Information Sciences, v. 40, n. 7, p. 1375, 2015.

EPIPHANIO, J. C. N.; LUIZ, A. J. B.; FORMAGGIO, A. R. Estimativa de áreas agrícolas municipais, utilizando sistema de amostragem simples sobre imagens de satélite. **Bragantia**, v. 61, n. 2, p. 187-197, 2002.

FIGUEIREDO, G. C.; VIEIRA, C.A.O. Estudo do comportamento dos índices de exatidão global, Kappa e Tau, comumente usados para avaliar a classificação de imagens de sensoriamento remoto. In: **Anais Simpósio Brasileiro de Sensoriamento Remoto**, 13, Florianópolis: INPE, p. 5755-62, 2007.

FISCHER, William A.; HEMPHILL, W. R.; KOVER, Allan. Progress in remote sensing (1972–1976). **Photogrammetria**, v. 32, n. 2, p. 33-72, 1976.

FLAASH, ENVI. FLAASH Module User's Guide. Research System. 2005.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. Oficina de textos, 2002.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3ª ed. São Paulo: Oficina de Textos, 2011.

FUSSELL, J.; RUNDQUIST, D.; HARRINGTON JR, J. A. On defining remote sensing. **Photogrammetric engineering and remote sensing**, v. 52, n. 9, p. 1507-1511, 1986.

GALLETTI, C. S.; MYINT, S. W. Land-use mapping in a mixed urban-agricultural arid landscape using object-based image analysis: A case study from Maricopa, Arizona. **Remote Sensing**, v. 6, n. 7, p. 6089-6110, 2014.

GAO, B.-C.; HEIDEBRECHT, K. B. GOETZ, A. F. H. Derivation of scaled surface reflectances from AVIRIS data. **Remote Sensing of Environment**. 44:165-178, 1993.

GOMES, Daniel et al. Avaliação comparativa de correção atmosférica de imagens Landsat utilizando MODTRAN e Dark Object Subtraction. **Simpósio Internacional SELPER**, v. 15, p. 236-245, 2012.

GORELICK, Noel. Google Earth Engine. In: **EGU General Assembly Conference Abstracts**. 2013. p. 11997.

GROTZINGER, J.; JORDAN, T. **Para Entender a Terra**; tradução: Iuri Durquia Abreu; revisão técnica: Rualdo Menegal. 6ª ed. Dados eletrônicos. Porto Alegre: Bookman, 2013.

GUO, Yunkai; ZENG, Fan. Atmospheric correction comparison of Spot-5 Image based on model Flaash and model Quac. **ISPRS Int Arch Photogramm Remote Sens Spat Inf Sci**, v. 39, n. B7, p. 7-11, 2012.

HELLDEN, U. STERN, M. Evaluation of Landsat Imagery and Digital Data for Monitoring Desertification Indicators in Tunisia. Proc. 14th. Int. **Symposium on Remote Sensing of Environment**, p. 1601-1611, 1980.

HOLBEN, B. N. et al. AERONET—A federated instrument network and data archive for aerosol characterization. **Remote sensing of environment**, v. 66, n. 1, p. 1-16, 1998.

HUECK, K. **As florestas da América do Sul: ecologia, composição e importância econômica**. São Paulo: Polígono, p.466, 1972.

HUETE, A. R., 1986, Separation of soil-plant spectral mixture by factor analysis. **Remote Sensing of Environment**, 19:237-251.

HUETE, A.; JUSTICE, C.; VAN LEEUWEN, W. MODIS vegetation index (MOD13). **Algorithm theoretical basis document**, v. 3, p. 213, 1999.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa de Biomas e de Vegetação**. Rio de Janeiro, 2004. Disponível em: <<http://www.ibge.gov.br/home/presidencia/noticias/21052004biomashtml.shtm>>. Acesso em: 19 out. 2016.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa Técnico e Uso da Terra**. Rio de Janeiro, 2006. Disponível em: <<http://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>>. Acesso em: 20 nov. 2016.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual Técnico da Vegetação Brasileira**. 2ª ed. revisada e ampliada. 2012. 271p.

IRONS, J. R.; DWYER, J. L.; BARSÍ, J. A. The next Landsat satellite: The Landsat data continuity mission. **Remote Sensing of Environment**, v. 122, p. 11-21, 2012.

ITTEN, Klaus I.; MEYER, Peter. Geometric and radiometric correction of TM data of mountainous forested areas. **IEEE Transactions on geoscience and remote sensing**, v. 31, n. 4, p. 764-770, 1993.

IWAI, O. K. **Mapeamento do uso do solo urbano do Município de São Bernardo do Campo, através de imagens de satélites**. 2003. 127p. Dissertação (Mestrado em Engenharia) – Universidade de São Paulo, São Paulo, 2003.

JACOMINE, P.K.T. Solos sob caatingas: características e uso agrícola. In: ALVAREZ V.H.; FONTES, L.E.F.; FONTES, M.P.F. **O solo nos grandes domínios morfoclimáticos do Brasil e o desenvolvimento sustentável**. Viçosa, SBCS-UFV, 1996. 930p.

JENSEN, J. R., 1949. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução José Carlos Neves Epiphânio (coordenador)...[et al.] São José dos Campos – SP: Parêntese, 2009.

JIMODA, L. A. Effects of particulate matter on human health, the ecosystem, climate and materials: a review. **Facta universitatis-series: Working and Living Environmental Protection**, v. 9, n. 1, p. 27-44, 2012.

KANTAKUMAR, L. N.; NEELAMSETTI, P. Multi-temporal land use classification using hybrid approach. **The Egyptian Journal of Remote Sensing and Space Science**, v. 18, n. 2, p. 289-295, 2015.

KLECKA, W. R. **Discriminant Analysis**. SAGE Publications, Inc., Beverly Hills, California, 71 p., 1980.

KÖRTING, T. S. **Classificação de imagens por regiões**. São José dos Campos, 2006.

KOSCHMIEDER, H. Theorie der horizontalen Sichtweite, Beitr. Phys. frei. Atmos., 12, 171–181, 1924.

KUMAR, R.; ACHARYA, P. Flood hazard and risk assessment of 2014 floods in Kashmir Valley: a space-based multisensor approach. **Natural Hazards**, v. 84, n. 1, p. 437-464, 2016.

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

LATORRE, M. L., CARVALHO JÚNIOR, O. A. D., CARVALHO, A. P. F. D. SHIMABUKURO, Y. E. Correção atmosférica: conceitos e fundamentos. **Espaço & Geografia**, v. 5. Nº 1, 2002, 153-178.

LEAL, I. R.; SILVA, J. M. C. **Ecologia e conservação da Caatinga**. Recife: Editora Universitária UFPE, 2003.

LEVADA, A. L. M. **Combinação de modelos de campos aleatórios markovianos para classificação contextual de imagens multiespectrais**. 146p. Tese (Doutorado) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2010.

LILLESAND, T. M.; KIEFFER, R. W. Remote sensing and photo interpretation. **New York: John Wiley and Sons**, 1994, p. 750.

LINTZ, J.; SIMONETT, D. S. **Remote Sensing of Environment**. Reading, MA: Addison-Wesley, 1976, 694 p.

LIOTTE, S.V; MACEDO, A. B. **Utilização de técnicas de geoprocessamento para apoio ao planejamento físico- territorial do município de Pariqueira-Açu**. Universidade de São Paulo. São Paulo, 2000.

LIOU, K.N. **An Introduction to atmospheric radiation**. Academic Press, New York, 392p, 1980.

LV, Z.; YU, X.; ZHANG, Z.; WANG, G. Automatic Remote Sensing Image Classification Method Based on Spectral Angle and Spectral Distance. **Geoscience and Remote Sensing Symposium (IGARSS) IEEE International** (pp. 3140-3143), 2013.

MACHADO, C. G. **A Caatinga e suas aves**. ComCiência, Campinas, n. 149, jun. 2013. Disponível em: http://comciencia.scielo.br/scielo.php?script=sci_arttext&pid=S151976542013000500007&lng=pt&nrm=iso. Acesso em: 07 dez. 2016.

MALDONADO, F.D. **Desenvolvimento e avaliação de uma metodologia de detecção de mudanças na cobertura vegetal do semiárido**. 2005. Tese (Doutorado em Sensoriamento Remoto) – Programa de Pós-Graduação em Sensoriamento Remoto, INPE, São José dos Campos – SP.

MANDANICI, E. Comparison between empirical and physically based models of atmospheric correction. In: **Third International Conference on Remote Sensing and Geoinformation of the Environment**. International Society for Optics and Photonics, 2015.

MARKHAM, B. L.; BAKER, J. K. LANDSAT MSS and TM post-calibration dynamics ranges, atmospheric reflectance and at-satellite temperatures. **EOSAT LANDSAT Technical Notes. No. 1 EOSAT**, 1986.

MARTINS, E.S.P.R. **Mapeamento e Avaliação do Potencial Hídrico Subterrâneo dos Aluviões em Zonas Semiáridas Utilizando Técnicas de Sensoriamento Remoto e SIG**. FUNCEME, Fortaleza, pp. 184, 2007.

MATHER, P. M. **Computer Processing of Remotely-Sensed Images. An Introduction**. 1ª Ed. John Wiley & Sons, Chichester, 1987.

MATHER, P.M. **Computer processing of remotely-sensed images: an introduction**. 3ª Ed. Chichester: John Wiley & Sons, 2004. 324p.

MELO, D.H.C.T.B. **Uso de dados IKONOS II na análise urbana: testes operacionais na zona leste de São Paulo** / D. H. C. T. B. Melo. - São José dos Campos: INPE, 2002. 146p.

MENESES, P. R. **Princípios de sensoriamento remoto: definição de sensoriamento remoto**. In: MENESES, P. R.; ALMEIDA, T. (Orgs.) In: Introdução ao Processamento de Imagens de Sensoriamento Remoto. Brasília: CNPQ, 2012 p. 1-33.

MIKHAIL, E.; ACKERMAN, F. **Observations and least squares**. United States: University Press of America, p. 497, 1976.

MISHRA, N.; HAQUE, M. O.; LEIGH, L.; AARON, D.; HELDER, B.; MARKHAM, B. Radiometric cross calibration of Landsat 8 operational land imager (OLI) and Landsat 7 enhanced thematic mapper plus (ETM+). **Remote Sensing**, v. 6, n. 12, p. 12619-12638, 2014.

MITCHELL, J. J.; SHRESTHA, R.; MOORE-ELLISON, C. A.; GLENN, N. F. Single and multi-date Landsat classifications of basalt to support soil survey efforts. **Remote Sensing**, v. 5, n. 10, p. 4857-4876, 2013.

MONICO, J. F. G.; POZ, A. P. D.; GALO, M.; SANTOS, M. C.; OLIVEIRA, L. C. Acurácia e precisão: revendo os conceitos de forma acurada. **Boletim de Ciências Geodésicas**, sec. Comunicações, Curitiba, v. 15, n. 3, p. 469-83, julho/setembro 2009.

MORAES, EC. **Fundamentos de sensoriamento remoto**. São José dos Campos: INPE, 2002.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: INPE, 2001. 250 p.

NASCIMENTO, E. R. P.; SANO, E. E. Identificação de Cerrado Rupestre por meio de imagens multitemporais do Landsat: proposta metodológica. **Sociedade e Natureza, Uberlândia**, v. 23, n. 1, p. 93-106, 2010.

NIMER, E. **Climatologia do Brasil**. 2ª.ed. Rio de Janeiro: Fundação IBGE, 1989. 421p.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Edgard Blücher, 1989. 308 p.

NOVO, E. M. L. M. **Sensoriamento remoto princípios e aplicações**. 2º Ed. São Paulo: Edgard Blücher, 1995.

NOZAWA A. **Carta do mundo ao milionésimo: subdivisões e localizações**. GEOGRAFIA (Londrina), v. 4, p. 49-53, 1987.

OC – OBSERVATÓRIO DO CLIMA. Sistema de Estimativa de Emissões de Gases de Efeito Estufa (SEEG) – Mudança de Uso da Terra. **Observatório do Clima [online]**, 2013.

OC – OBSERVATÓRIO DO CLIMA. **Análise da evolução das emissões de GEE no Brasil (1970–2013) e suas implicações para políticas públicas**. São Paulo: Observatório do Clima, 2015.

PASSO, D. P. **Análise da qualidade de classificadores para identificação de alvos urbanos em imagens de alta resolução espacial: uma aplicação com as imagens do satélite Worldview II**. Dissertação de Mestrado – Universidade de Brasília, 2013.

PATHAK, Vishal N.; PANDYA, M. R.; SHAH, D. B.; TRIVEDI, H. J.; PATEL, K. D.; SRIDHAR, V. N.; SINGH, R. P. Inter Comparison of Atmospheric Correction Models-SACRS2, FLAASH and 6SV Using Resourcesat-2 AWiFS Data. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, n. 8, p. 881, 2014.

PONZONI, F. J. **Sensoriamento remoto: reflectância de alvos naturais.** MENESES, P. R.; MADEIRA NETTO, J. (Org.). Brasília: UnB, Planaltina: Embrapa Cerrados, 2001, 262 p.

PONZONI, F. J. **Sensoriamento remoto no estudo da vegetação: diagnosticando a mata atlântica.** São José dos Campos: INPE, 2002.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação.** São José dos Campos, São Paulo: A. Silva Vieira, 2007, 144 p.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação.** 2ª edição atualizada e ampliada. São Paulo: Oficina de Textos, 2012.

PRADO, Darién E. As caatingas da América do Sul. **Ecologia e conservação da Caatinga**, v. 2, p. 3-74, 2003.

PRADO, F. A. **Sistema hierárquico de classificação para mapeamento da cobertura da terra nas escalas regional e urbana.** [Dissertação de mestrado da Universidade Estadual Paulista, Campus de Presidente Prudente]. São Paulo, p. 164, 2009.

QUEIROZ, J. E. R.; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **Revista RITA**, Volume III, Número 1, 2001.

RAMOS, O. T. H. **Análise Comparativa entre os principais formatos de armazenamento de imagens.** Dissertação de Mestrado pela Universidade Presbiteriana Mackenzie. São Paulo, 2000.

RASHED, T.; WEEKS, J. R.; ROBERTS, D.; ROGAN, J.; POWELL, R. Measuring the physical composition of urban morphology using multiple endmember spectral mixture models. **Photogrammetric Engineering & Remote Sensing**, v. 69, n. 9, p. 1011-1020, 2003.

RIBEIRO, B. M. G. et al. Avaliação da influência do efeito atmosférico na identificação do estado de conservação da cobertura vegetal intra-urbana em imagens de alta resolução espacial. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 14, p. 827-834, 2009

RICHARDS, John A.; RICHARDS, J. A. **Remote sensing digital image analysis.** Berlin et al.: Springer, 1999.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis-hardback.** Springer, 2006.

RIZZINI, C. T. **Tratado de fitogeografia do Brasil: aspectos ecológicos, sociológicos e florísticos.** Rio de Janeiro: Âmbito Cultural, 1997, p. 748.

RODAL, M. J. N.; SAMPAIO, E. V. S. B. A vegetação do bioma caatinga. **Vegetação & Flora da Caatinga: 2002**; Recife. Editado por SAMPAIO E. V. S. B., GIULIETTI A. M., VIRGINIO J., GAMARRA-ROJAS C. F. L., p. 49-90, 2002.

RODRIGUES, F. **Análise da profundidade óptica do aerossol obtida a partir de distintas plataformas na região de Campo Grande/MS.** 99 p. Dissertação (Mestrado). Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2016.

ROJAS, E. H. M. **Síntese Genética de Redes Neurais Artificiais ART2 na classificação de imagens ASTER para mapeamento de uso e cobertura da terra na região Norte de Mato Grosso. 2005.** 126f. Dissertação (Mestrado do Curso de Pós-graduação em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais – INPE. São José Dos Campos. 2005.

ROSA, R. S.; MENEZES, N. A.; BRITSKI, H. A.; COSTA, W. J. E. M.; GROTH, F. Diversidade, padrões de distribuição e conservação dos peixes da Caatinga. In: LEAL, I. R.; TABARELLI, M.; SILVA, J. M. C. **Ecologia e conservação da Caatinga.** Recife: Editora Universitária UFPE, 2003.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric engineering and remote sensing**, v. 52, n. 2, p. 223-227, 1986.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A. DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS.** In S. C. Freden & M. A. Becker (Eds.), *Third ERTS Symposium* (pp. 309–317). Greenbelt, MD: NASA Goddard Space Flight Center, 1973.

RUNNING, S. W. et al. Terrestrial remote sensing science and algorithms planned for EOS/MODIS. **International journal of remote sensing**, v. 15, n. 17, p. 3587-3620, 1994.

SÁ, I.B.; SILVA, P.C.G (Eds). **Semiárido brasileiro: pesquisa, desenvolvimento e inovação.** Petrolina, Embrapa Semiárido, 2010. 402p.

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

SAINI, V.; TIWARI, R. K.; GUPTA, R. P. Comparison of FLAASH and QUAC atmospheric correction methods for Resourcesat-2 LISS-IV data. In: **SPIE Asia-Pacific Remote Sensing.** International Society for Optics and Photonics, 2016.

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

SHIWEI, X. et al. Application of MODTRAN Model in Atmospheric Correction of HJ/CCD Data. **Meteorological & Environmental Research**, v. 7, n. 6, 2016.

SILVA, F.B.R.; RICHÉ, G.R.; TONNEAU, J.P.; SOUSA NETO, N.C.; BRITO, L.T.L.; COREIA, R.C.; CAVALCANTI, A.C.; SILVA, F.H.B.B.; SILVA, A.B.; ARAÚJO FILHO,

J.C. **Zoneamento agroecológico do Nordeste: diagnóstico do quadro natural e agrossocioeconômico. Petrolina, PE: EMBRAPA-CPATSA/Recife: EMBRAPA CNPS. Coordenadoria Regional Nordeste, 1993. 2v. (EMBRAPA-CPATSA. Documentos, 80).**

SMITH, M. O., JOHNSON, P. E., & ADAMS, J. J. Quantitative determination of mineral types and abundances from reflectance spectra using principal components analysis. **Journal of Geophysical Research**, 90, 1985, pp. 797–804.

SONG, C.; WOODCOCK, C. E.; SETO, K. C.; LENNEY, M. P.; MACOMBER, S. A. Classification and change detection using Landsat TM data: When and how to correct atmospheric effects? **Remote sensing of Environment**, v. 75, n. 2, p. 230-244, 2001.

SOUZA JR., C. M., ROBERTS, D.; COCHRANE, M. A. **Combining Spectral and Spatial Information to Map Canopy Damages from Selective Logging and Forest Fires. Remote Sensing of Environment. 98. 329-343, 2005.**

STORY, M.; CONGALTON, R.G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, 52(3): 397-399, 1986.

TOMPKINS, S.; MUSTARD, J. F.; PIETERS, C. M; FORSYTH, D. W. Optimization of endmembers for spectral mixture analysis. **Remote Sensing of Environment**, v. 59, n. 3, p. 472-489, 1997.

TUOMINEN, S.; PEKKARINEN, A. Local radiometric correction of digital aerial photographs for multi-source forest inventory. **Remote Sensing of Environment**, v. 89, n. 1, p. 72-82, 2004.

TURNER, D. D.; FERRARE, R. A.; BRASSEUR, L. A. Average aerosol extinction and water vapor profiles over the Southern Great Plains. **Geophysical research letters**, v. 28, n. 23, p. 4441-4444, 2001.

USGS – UNITED STATES GEOLOGICAL SURVEY. **Landsat data continuity mission.** U.S. Department of the Interior, U.S. Geological Survey. 2012–3066. July 2012.

VALENTE, R. de O. A. **Análise da Estrutura da Paisagem na Bacia do Rio Corumbataí.** 144p. Dissertação (mestrado) – Escola Superior de Agricultura Luiz de Queiroz da Universidade de São Paulo, 2001.

VAN AARDT, J. A. N.; LÜCK-VOGEL, M.; LÜCK, W.; ALTHAUSEN, J. D. Remote-Sensing Systems for Operational and Research Use. In: BOSSLER, J. D.; CAMPBELL, J. B.; MCMASTER, R. B.; RIZOS, C. **Manual of Geospatial Science and Technology.** Boca Raton: Taylor & Francis, 2010. Cap. 18, p. 319-362.

VASCONCELOS, Cíntia Honório; NOVO, E. M. L. M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens—fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do

sensor TM/Landsat5, na região do reservatório de Tucuruí-PA. **Acta Amazônica**, v. 34, n. 3, p. 487-493, 2004.

VELLOSO, A. L.; SAMPAIO, E. V. S.; PAREYN, F. S. G. C. **Ecorregiões propostas para o bioma Caatinga**. Recife: APNE - Associação Plantas do Nordeste, TNC, 2002, 76 p.

WEISS, C. V. C.; CAMARGO, D. C. S.; ROSCA, E. H.; ESPINOZA, J. Análise comparativa entre métodos de correção atmosférica em imagens do sensor Operational Land Imager (OLI), plataforma Landsat 8. **Scientia Plena**, v. 11, n. 2, 2015.

WENG, Q. **Remote sensing and GIS integration: theories, methods, and applications**. New York: McGraw-Hill, 2010.

WILSON, E.H. SADER, S.A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, 80, pp. 385 –396, 2002.
XIAO, D.; LE, B. T.; MAO, Y.; JIANG J.; SONG, L.; LIU, S. Research on Coal Exploration Technology Based on Satellite Remote Sensing. **Journal of Sensors**, v. 2016, 2016.

WMO – World Meteorological Organization. **WMO statement on the status of global climate**. [online]. Acesso em: dezembro/2016.

YUAN, J.; NIU, Z. Evaluation of atmospheric correction using FLAASH. In: **Earth Observation and Remote Sensing Applications. EORSA 2008. International Workshop on**. IEEE, 2008. p. 1-6.

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

ZULLO JÚNIOR, J. **Correção atmosférica de imagens de satélite e aplicações. Tese de Doutorado**. Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas (UNICAMP), Campinas, 1994.

Apêndice 1 – Script com a rotina para obtenção do mosaico temporal do Landsat em números digitais (dado bruto)

```

/**
 * Notes:
 * 1 - Remember to create a folder "ee_export" on you Google Drive
 * 2 - Landsat 5 and 7 data have 8 bits
 * 3 - Landsat 8 has 16 bits (largest imagery)
 */

/**
 * Options to use in your mosaic
 * @type {Object}
 */

// Colld
//LT5_L1T - Landsat 5
//LE7_L1T - Landsat 7
//LC8_L1T - Landsat 8

var options = {
  "gridName": "SC-24-V-C",
  "t0": "2015-01-01",
  "t1": "2015-06-30",
  "Colld": "LC8_L1T",
  "cloudCover": 1,

  "gridft": 'ft:1wCmguQD-xQs2gMH3B-hdOdrwy_hZAq4XFW1rU8PN',

  "vis": {
    "bands": ["B5", "B4", "B3"],
    "gain": [2.0, 2.0, 2.0],
    "gamma": 0.5
  }
};
/**-----*/

// Get feature
var gridfc = ee.FeatureCollection(options.gridft)
  .filterMetadata("name", "equals", options.gridName);

```

```
// Get collection
var collection = ee.ImageCollection(options.CollId)
  .filterMetadata("CLOUD_COVER", "less_than", options.cloudCover)
  .filterDate(options.t0, options.t1)
  .filterBounds(gridfc)
  .map(
    function(image) {
      var polygon = image.geometry();
      return image.clip(polygon.buffer(-5700.0));
    }
  );

// Make median mosaic
var mosaic = collection.median().clip(gridfc);

if (options.CollId === "LC8_L1T") {
  mosaic = mosaic.int16();
  options.vis.bands = ["B6", "B5", "B4"];
  options.vis.gain = [0.01, 0.01, 0.01];
} else {
  mosaic = mosaic.int8();
}

Map.addLayer(mosaic,
  options.vis,
  "mosaic",
  true
);

Map.centerObject(gridfc);

Export.image.toDrive({
  "image": mosaic,
  "description": options.gridName,
  "folder": "ee_export",
  "region": gridfc.geometry().buffer(5000).coordinates(),
  "scale": 30,
  "maxPixels": 1e13
});
```

Apêndice 2 – Script com a rotina constando todos os parâmetros envolvidos na obtenção da classificação da cobertura do solo para as cartas

```

var anos = [
'2015'
];

//Região 1
var cartaslist = [
// 'SD-23-X-D'
'SC-24-V-C'
];

var t = new Date();
var elevCotas = {on:0, elevMin:0, elevMax:20};

// Tabela com Parâmetros
var paramsFusionTable = "ft:1tejyB1j-Rvxo2j4ZBqce8ISyUOkDBelM5l_2hLzy"; //Soltan, Marcus,
APNE, Juvenal 2000-2001
var paramsFeatureCollection = ee.FeatureCollection(paramsFusionTable);

// Grid com cartas 1:250.000
var gridFusionTable = "ft:1wCmguQD-xQs2gMH3B-hdOdrwy_hZAq4XFW1rU8PN";
var gridFeatureCollection = ee.FeatureCollection(gridFusionTable);

// Fusion Table com o limite do BIOMA
// Fonte: IBGE. 5.000.000, 2007
var biomaFusionTable = "ft:1H32agP9xr-BIDKl4irmhFCLxI5_TOs9nvbEz-C6u";
var biomaFeatureCollection = ee.FeatureCollection(biomaFusionTable);

// Fusion Table com o limite dos Estados Brasileiros
// Fonte: IBGE 500.000, 2010
var ufFusionTable = "ft:1n-9np_o8hbDaCuYFwhkgEuIN8770mW0n302YyHGo";
var ufFeatureCollection = ee.FeatureCollection(ufFusionTable);

//*****

```

```
// Início da Rotina
```

```
/*******
```

```
/*
```

```
=====
```

```
FUNCTION NAME:
```

```
    cloudMask
```

```
PURPOUSE:
```

```
    Make a cloud mask using mosaic
```

```
ARGUMENTS:
```

```
    [arg1] mosaic
```

```
=====
```

```
*/
```

```
var cloudMaskL8 = function(image){
  var cfmask_conf = ee.Image(image.select(['fmask']));
  var image = image.mask(cfmask_conf.neq(4));
  return image
};
```

```
var cloudMask_anoL8 = function(image){
  var cfmask_conf = ee.Image(image.select(['fmask']));
  var image = image.mask(cfmask_conf.neq(4));
  var b1_conf = ee.Image(image.select(['B2']));
  var image = image.mask(b1_conf.lt(0.15));
  return image
};
```

```
//Função que aplica uma máscara que remove os pixels com sombra de nuvem
```

```
//Essa função recebe cada imagem Landsat e retorna a imagem sem sombra de nuvem
```

```
var shadowMask = function(image){
  var cfmask_conf = ee.Image(image.select(['fmask']));
  return image.mask(cfmask_conf.neq(2));
};
```

```
var shadowMaskL8 = function(image){
  var cfmask_conf = ee.Image(image.select(['fmask']));
```



```

return image.mask(cfmask_conf.neq(2));
};

```

```

/*

```

```

=====
FUNCTION NAME:

```

```

    edgeRemoval

```

```

PURPOUSE:

```

```

    Remove os ruídos das bordas da imagem

```

```

ARGUMENTS:

```

```

    [arg1] image

```

```

=====
*/

```

```

var removeborda = function(image){
    var polygon = image.geometry();
    return image.clip(polygon.buffer(-5500.0));
};

```

```

/*

```

```

=====
FUNCTION NAME:

```

```

    getFractions

```

```

Objetivo/Objective:

```

```

    Get fraction images from L8 images

```

```

ARGUMENTS:

```

```

    [arg1] Surface reflectance image, info

```

```

=====
*/

```

```

var getFractionsL8 = function(image){
    // Define endmembers

```

```

var coef = 10000;

```

```

var bandNames = ['B2','B3','B4','B5','B6','B7'];

```

```

var outBandNames = ['gv', 'npv', 'soil', 'cloud'];

```

```

    // Define atmosphere

```

```

// var atm = [805.6, 458.1, 286.8, 168.3, 46.8, 26.6];

```

178

```
var atm = [0, 0, 0, 0, 0, 0];
// Define endmembers
var endmembers =
[
[ 1199.0+atm[0], 475.0+atm[1], 169.0+atm[2],6250.0+atm[3],2399.0+atm[4], 675.0+atm[5]],//
GV
[1514.0+atm[0],1597.0+atm[1],1421.0+atm[2],3053.0+atm[3],7707.0+atm[4],1975.0+atm[5]],//
NPV
[1799.0+atm[0],2479.0+atm[1],3158.0+atm[2],5437.0+atm[3],7707.0+atm[4],6646.0+atm[5]],//
Soil
[4031.0+atm[0],8714.0+atm[1],7900.0+atm[2],8989.0+atm[3],7002.0+atm[4],6607.0+atm[5]] //
Cloud
];

// Uminxing data
var fractions = image
.select(bandNames)
.multiply(coef)
.unmix(endmembers)
.max(0)
.multiply(100)
.toByte();

fractions = fractions.select([0, 1, 2, 3], outBandNames);
// image = image.addBands({
//   'srclmg': fractions,
//   'names': outBandNames,
//   'overwrite': true
//   });

return fractions;
};

/*
=====
FUNCTION NAME:
getNDFI
```

Objetivo/Objective

Get NDFI from L5 and L7 and L8 images

ARGUMENTS:

[arg1] fraction images

```

=====
*/
var getNDFI = function(fractions){
  // Calculate NDFI
  var summed = fractions.select(['gv', 'npv', 'soil']).reduce(ee.Reducer.sum());
  var gv = fractions.select('gv');
  var npv = fractions.select('npv');
  var soil = fractions.select('soil');
  var cloud = fractions.select('cloud');

  var gvs = (fractions.select('gv').divide(summed)).multiply(100).toByte();
  var gvnnpv = gv.add(npv);
  var gvsnnpv = gvs.add(npv);
  var gvnnpv_s = (gvnpv.divide(summed)).multiply(100);
  var shade = summed.subtract(100).abs();
  var soilcloud = fractions.select('soil').add(fractions.select('cloud'));
  var soilshade = fractions.select('soil').add(shade);

  //npv + soil + cloud
  var npvSoil = fractions.select('npv').add(fractions.select('soil'));

  //calculate NDFI
  var ndfi = ee.Image.cat(gvs, npvSoil).normalizedDifference();

  //rescale NDFI from 0-200
  ndfi = ndfi.multiply(100).add(100).byte();

  return ndfi;
};

```

```
/*
```

```
=====
FUNCTION NAME:
```

180

getNDFI3

Objetivo/Objective::

Get ndfi3 from L5 and L7 and L8 images

ARGUMENTS:

[arg1] fraction images

```
=====
=====
```

```
*/
```

```
var getNDFI3 = function(fractions){
  // Calculate NDFI
  var summed = fractions.select(['gv', 'npv', 'soil']).reduce(ee.Reducer.sum());
  var gv = fractions.select('gv');
  var npv = fractions.select('npv');
  var soil = fractions.select('soil');
  var cloud = fractions.select('cloud');

  var gvs = (fractions.select(0).divide(summed)).multiply(100);
  var gvnvpv = gv.add(npv);
  var gvsnpv = gvs.add(npv);
  var gvnvpv_s = (gvnpv.divide(summed)).multiply(100);
  var shade = summed.subtract(100).abs();
  var soilcloud = fractions.select(2).add(fractions.select(3));
  var soilshade = fractions.select(2).add(shade);

  //npv + soil + cloud
  var npvSoil = fractions.select(1).add(fractions.select(2)).add(fractions.select(3));

  //calculate NDFI
  var ndfi3 = ee.Image.cat(gvnvpv_s, soilcloud).normalizedDifference();

  //rescale NDFI3 from 0-200
  ndfi3 = ndfi3.multiply(100).add(100).byte();

  return ndfi3;
```

```
};
```

```
/*
```

```
=====
FUNCTION NAME:
```

```
    decisionTree Decidual
```

```
PURPOUSE:
```

```
ARGUMENTS:
```

```
    [arg1] imagem sma
```

```
    [arg2] imagem ndfi
```

```
*/
```

```
var decisionTree_Decidual = function(info, sma, ndfi3, terrain, mosaico_ano_dif,fmask){
```

```
    // Rename fraction bands
```

```
    var gv  = sma.select('gv');
```

```
    var npv = sma.select('npv');
```

```
    var soil = sma.select('soil');
```

```
    var cloud = sma.select('cloud');
```

```
    // Rename ndfi bands
```

```
    var ndfi3 = ndfi3.select(0);
```

```
    // Get gvs
```

```
    var summed = sma.expression('b(0) + b(1) + b(2)');
```

```
    var gvs = (gv.divide(summed)).multiply(100);
```

```
    var shade = summed.subtract(100).abs();
```

```
    var gvss = (gv.divide(shade)).multiply(100);
```

```
    var gv_npv = (gv.add(npv));
```

```
    var npv_soil = (npv.add(soil))
```

```
    // Terrain
```

```
    var slope  = terrain.select(['slope']);
```

```
//  var aspect = terrain.select(['aspect']);
```

```
    // Variables
```

```
    var v1 = info.carta1.dtv.v1;
```

```
    var v2 = info.carta1.dtv.v2;
```

```
    var v3 = info.carta1.dtv.v3;
```

```
    var v4 = info.carta1.dtv.v4;
```

```
    var v5 = info.carta1.dtv.v5;
```

```
var v6 =info.carta1.dtv.v6;
var v7 =info.carta1.dtv.v7;
var v8 =info.carta1.dtv.v8;
var v9 =info.carta1.dtv.v9;
// Define classification image
var dataClass = ee.Image(0).toByte();

//Muito Alto NDFI

//Muito Alto NDFI

//var flo_densa1 = (ndfi3.gte(v1)).and(gv.lt(v2)).and(slope.gte(v6));
var flo_densa1 = (ndfi3.gte(v1)).and(gv.gte(v2)).and(slope.gte(v6));
dataClass = dataClass.where(flo_densa1.eq(1), 1); // flo_densa

var flo_densa2 = (ndfi3.gte(v1)).and(gv.lt(v2)).and(shade.gte(v7)).and(slope.gte(v6));
dataClass = dataClass.where(flo_densa2.eq(1), 1); // flo_densa3

var flo_densa3 = (ndfi3.gte(v1)).and(gv.lt(v2)).and(shade.lt(v7)).and(npv_soil.lt(v3));
dataClass = dataClass.where(flo_densa3.eq(1), 1); // flo_densa

var umida = (ndfi3.gte(v1)).and(gv.lt(v2)).and(shade.gte(v7)).and(slope.lt(v6));
dataClass = dataClass.where(umida.eq(1), 5); // umida

var flo_aberta = (ndfi3.gte(v1)).and(gv.lt(v2)).and(shade.lt(v7)).and(npv_soil.gte(v3));
dataClass = dataClass.where(flo_aberta.eq(1), 2); // flo_aberta

var agr_past1 = (ndfi3.gte(v1)).and(gv.gte(v2)).and(slope.lt(v6));
dataClass = dataClass.where(agr_past1.eq(1), 7); // agricultura/pastagem

var agricultura_amplitude = (ndfi3.gte(v1)).and(gv.lt(v2)).and(mosaico_ano_dif.gte(v8));
dataClass = dataClass.where(agricultura_amplitude.eq(1), 7); // agricultura_amplitude

//Alto NDFI

var nat_ao_flo = (ndfi3.lt(v1)).and(gvs.gte(v4)).and(shade.gte(v5)).and(shade.lt(v7));
dataClass = dataClass.where(nat_ao_flo.eq(1), 4); // nat_ao_flo
```

```

var nat_umido = (ndfi3.lt(v1)).and(gvs.gte(v4)).and(shade.gte(v5)).and(shade.gte(v7));
dataClass = dataClass.where(nat_umido.eq(1), 5); // nat_umido

var pasto = (ndfi3.lt(v1)).and(gvs.gte(v4)).and(shade.lt(v5));
dataClass = dataClass.where(pasto.eq(1), 7); // pasto

var solo_exp = (ndfi3.lt(v1)).and(gvs.lt(v4));//.and(shade.lt(55))
dataClass = dataClass.where(solo_exp.eq(1), 12); // pasto

var Agua = (shade.gte(85));
dataClass = dataClass.where(Agua.eq(1), 3); // Outros

return dataClass.mask(dataClass.neq(0));
};

/*
=====
FUNCTION NAME:
    mapAddLayers
PURPOUSE:
    Adiciona as camadas ao mapa
ARGUMENTS:
    [arg1]
    [arg2]
=====
*/
var mapAddLayers = function(data, mapinfo){

    var gridFusionTable = 'ft:1wCmguQD-xQs2gMH3B-hdOdrwy_hZAq4Xfw1rU8PN';
    var gridFeatureCollection = ee.FeatureCollection(gridFusionTable);

    var data2 = {
        myGrid: gridFeatureCollection.filterMetadata('name', "equals", mapinfo.gridName), //Limite
do grid
        terrain: ee.call('Terrain', ee.Image('USGS/SRTMGL1_003')), //Dados de elevação
        elevCotas: elevCotas
    };
};

```

```

if (data != -1){
  if (mapinfo.tag.ref) {Map.addLayer(data.reflect.clip(data2.myGrid), mapinfo.vis.ref,
mapinfo.year + "Mosaic "+ mapinfo.gridName, false);}
  var reflect = data.reflect.select(['B2','B3','B4','B5','B6','B7'],['B2','B3','B4','B5','B6','B7']);

  Export.image.toDrive(
  {
    image: reflect.float().clip(data2.myGrid),
    description: mapinfo.year + "Mosaic "+ mapinfo.gridName,
    scale: 30,
    maxPixels: 1e13,
    region:data2.myGrid
  })

  if (mapinfo.tag.sma) {Map.addLayer(data.sma.clip(data2.myGrid), mapinfo.vis.sma,
mapinfo.year + "SMA "+ mapinfo.gridName, false);}
  if (mapinfo.tag.ndfi){

    Map.addLayer(data.ndfi.select(0).clip(data2.myGrid), mapinfo.vis.ndfi, mapinfo.year + "NDFI
"+ mapinfo.gridName, false);

  }
  if (mapinfo.tag.dt) {
//   Map.addLayer(data.dTree.mask(data.dTree.neq(2)).clip(data2.myGrid),
    Map.addLayer(data.dTree.clip(data2.myGrid), mapinfo.vis.DT, mapinfo.year + "DTree "+
mapinfo.gridName, true);
  }
  Export.image.toDrive(
  {
    image: data.dTree.clip(data2.myGrid),
    description: mapinfo.gridName + "-class"+ mapinfo.year,
    scale: 30,
    maxPixels: 1e13,
    region:data2.myGrid
  })
}

```



```
};

/*
=====
FUNCTION NAME:
    getGridNameInfo
PURPOUSE:
    Lê informações de cada carta
ARGUMENTS:
    [arg1]
    [arg2]
=====
*/

var getGridNameInfo = function(features, gridname){
    var prop = -1;
    for (var i=0;i<features.length; i++){
        var feature = features[i];
        if (feature.properties.GRID_NAME == gridname){
            prop = {
                year: feature.properties.YEAR,
                t0: feature.properties.T0,
                t1: feature.properties.T1,
                cc: feature.properties.CLOUD_COVER,
                gridname: feature.properties.GRID_NAME,
                dtv:{
                    v1: feature.properties.DTV1,
                    v2: feature.properties.DTV2,
                    v3: feature.properties.DTV3,
                    v4: feature.properties.DTV4,
                    v5: feature.properties.DTV5,
                    v6: feature.properties.DTV6,
                    v7: feature.properties.DTV7,
                    v8: feature.properties.DTV8,
                    v9: feature.properties.DTV9
                },
                chave: feature.properties.CHAVE,
            }
        }
    }
}
```

```

    sensor: feature.properties.SENSOR,
    tag:{
      on: feature.properties.TAG_ON,
      ndfi: feature.properties.NDFI,
      sma: feature.properties.SMA,
      ref: feature.properties.REF,
      dt: feature.properties.DT
    },
    save: feature.properties.SAVE,
    bioma: feature.properties.BIOMA,
    region: feature.properties.REGION,
  };
}
}

return prop;
};

/*
=====
FUNCTION NAME:
  mapBiomassDolt
PURPOSE:
  Executa as funções da metodologia para um determinado ano
ARGUMENTS:
  [arg1] info.yYYYY (YYYY = ano)
  [arg2] data
=====
*/
var mapBiomassDolt = function(info, carta_atual){

  //cria a coleção de imagens e aplica o filtro por período
  if (info.carta1.tag.on) {
  // print(info.carta1.year+'-01-01')
    switch (info.carta1.sensor){
      case "L8":

```

```

var Colecao = ee.ImageCollection('LANDSAT/LC8_L1T_TOA_FMASK')
    .filterDate(info.carta1.t0, info.carta1.t1)
    .select(['B2','B3','B4','B5','B6','B7','fmask'])
    .filterMetadata("CLOUD_COVER", "less_than", info.carta1.cc)
    .filterBounds(carta_atual);
var Colecao_ano = ee.ImageCollection('LANDSAT/LC8_L1T_TOA_FMASK')
    .filterDate(info.carta1.year+'-01-01', info.carta1.year+'-12-30')
    .filterMetadata("CLOUD_COVER", "less_than", 50)
    .filterBounds(carta_atual);
var collection = Colecao
var collection_ano = Colecao_ano

//aplica a função que remove as bordas das imagens
var mosaicosemborda = collection.map(removeborda);
var mosaicosemborda_ano = collection_ano.map(removeborda);

//aplica a função que remove as nuvens de cada imagem da colecao
var ColecaosemNuvem = mosaicosemborda.map(cloudMaskL8);
var ColecaosemNuvem_ano = mosaicosemborda_ano.map(cloudMask_anoL8);

//aplica a função que remove as sombras de nuvens de cada imagem da colecao
var ColecaosemSombra = ColecaosemNuvem.map(shadowMaskL8);
var ColecaosemSombra_ano = ColecaosemNuvem_ano.map(shadowMaskL8);
break;
}

//cria a mediana do mosaico de imagens sem nuvem
var medianMosaic = ColecaosemSombra.median();

switch (info.carta1.sensor){
case "L8":
    var smaMosaic = ColecaosemSombra.map(getFractionsL8);
    var SMAano = ColecaosemSombra_ano.map(getFractionsL8)
    var cfmask = 'fmask';
    break;
}

```

188

```
//cria ndfi
var ndfiMosaic = smaMosaic.map(getNDFI);
var ndfi3Mosaic = smaMosaic.map(getNDFI3);

smaMosaic = smaMosaic.median();
ndfiMosaic = ndfiMosaic.median();
ndfi3Mosaic = ndfi3Mosaic.median();

var NDFIano = SMAano.map(getNDFI)
var NDFI3ano = SMAano.map(getNDFI3)

var ndfiMosaic_ano_min = NDFIano.min();
var ndfi3Mosaic_ano_min = NDFI3ano.min();

var ndfiMosaic_ano_max = NDFIano.max();
var ndfi3Mosaic_ano_max = NDFI3ano.max();

var mascara_ndfi = ee.Image(ndfiMosaic_ano_min.select([0]));
var ndfiMosaic_ano_min = ndfiMosaic_ano_min.mask(mascara_ndfi.gte(1));

var mascara_ndfi3 = ee.Image(ndfi3Mosaic_ano_min.select([0]));
var ndfi3Mosaic_ano_min = ndfi3Mosaic_ano_min.mask(mascara_ndfi3.gte(1));

var mosaico_ano_dif = ndfiMosaic_ano_max.subtract(ndfiMosaic_ano_min)
var mosaico_ano_dif3 = ndfi3Mosaic_ano_max.subtract(ndfi3Mosaic_ano_min)

//define MDT
var terrain = ee.call('Terrain', ee.Image('USGS/SRTMGL1_003'));
var slope = terrain.select(['slope']);

//gera classificacao
switch (info.carta1.chave){
  case 2:
```

```

        var dTree = decisionTree_Decidual(info, smaMosaic, ndfi3Mosaic, terrain,
mosaico_ano_dif3,cfmask);
        var visDT =
{'min':1,'max':12,'palette': '#006400,#00D100,#0000FF,#C2DB6E,#45C2A5,#65C24B,#F0F020,#F
F0000,#000000,#E858E4,#FFAD2A,#B5BAD6','format':'png'};
        break;
    }

    var result = {dTree: dTree, ndfi: ndfi3Mosaic, sma: smaMosaic, reflect: medianMosaic, visDT:
visDT};
    } else {
        var result = -1;
    }
    return result;
};

/*
=====
SCRIPT PRINCIPAL
=====
*/

//define legendas
var visSMA = {'bands':['soil', 'gv', 'npv'], 'gain': [6.0,4.0,6.0]};

//cria paleta de cores (branco - Rosa - Amarelo - Laranja - Verde Claro - Verde Escuro)
var ndfi_color =
'FFFFFF,FFFCFF,FFF9FF,FFF7FF,FFF4FF,FFF2FF,FFEFFF,FFECFF,FFE AFF,FFE7FF,'+
'FFE5FF,FFE2FF,FFE0FF,FFDDFF,FFDAFF,FFD8FF,FFD5FF,FFD3FF,FFD0FF,FFCEFF,'+
'FFCBFF,FFC8FF,FFC6FF,FFC3FF,FFC1FF,FFBEFF,FFBCFF,FFB9FF,FFB6FF,FFB4FF,'+
'FFB1FF,FFAFFF,FFACFF,FFAAFF,FFA7FF,FFA4FF,FFA2FF,FF9FFF,FF9DFF,FF9AFF,'+
'FF97FF,FF95FF,FF92FF,FF90FF,FF8DFF,FF8BFF,FF88FF,FF85FF,FF83FF,FF80FF,'+
'FF7EFF,FF7BFF,FF79FF,FF76FF,FF73FF,FF71FF,FF6EFF,FF6CFF,FF69FF,FF67FF,'+
'FF64FF,FF61FF,FF5FFF,FF5CFF,FF5AFF,FF57FF,FF55FF,FF52FF,FF4FFF,FF4DFF,'+
'FF4AFF,FF48FF,FF45FF,FF42FF,FF40FF,FF3DFF,FF3BFF,FF38FF,FF36FF,FF33FF,'+
'FF30FF,FF2EFF,FF2BFF,FF29FF,FF26FF,FF24FF,FF21FF,FF1EFF,FF1CFF,FF19FF,'+
'FF17FF,FF14FF,FF12FF,FF0FFF,FF0CFF,FF0AFF,FF07FF,FF05FF,FF02FF,FF00FF,'+
'FF00FF,FF0AF4,FF15E9,FF1FDF,FF2AD4,FF35C9,FF3FBF,FF4AB4,FF55AA,FF5F9F,'+

```

```
'FF6A94,FF748A,FF7F7F,FF8A74,FF946A,FF9F5F,FFAA55,FFB44A,FFBF3F,FFC935,'+
'FFD42A,FFDF1F,FFE915,FFF40A,FFFF00,FFFF00,FFFB00,FFF700,FFF300,FFF000,'+
'FFEC00,FFE800,FFE400,FFE100,FFDD00,FFD900,FFD500,FFD200,FFCE00,FFCA00,'+
'FFC600,FFC300,FFBF00,FFBB00,FFB700,FFB400,FFB000,FFAC00,FFA800,FFA500,'+
'FFA500,F7A400,F0A300,E8A200,E1A200,D9A100,D2A000,CA9F00,C39F00,BB9E00,'+
'B49D00,AC9C00,A59C00,9D9B00,969A00,8E9900,879900,7F9800,789700,709700,'+
'699600,619500,5A9400,529400,4B9300,439200,349100,2D9000,258F00,1E8E00,'+
'168E00,0F8D00,078C00,008C00,008C00,008700,008300,007F00,007A00,007600,'+
'007200,006E00,006900,006500,006100,005C00,005800,005400,005000,004C00';
```

```
//define os parâmetros de visualização das imagens Landsat 8
```

```
var visParMedianL5 = {'bands':['B7','B4','B3'], 'gain':[0.12,0.06,0.06]};
```

```
var visParMedianLX = {'bands':['B7','B4','B3'], 'gain':[0.12,0.06,0.06]};
```

```
var visParMedianL8 = {'bands':['B6','B5','B4'], 'gain':[800,600,2000],'gamma':0.5};
```

```
var visNDFI = {'min':0, 'max':200, 'palette':ndfi_color};
```

```
var featuresTable = [];
```

```
var featureCol = null;
```

```
for (var i_ano=0;i_ano<anos.length; i_ano++){
```

```
  var ano = anos[i_ano];
```

```
  var fcSelected = paramsFeatureCollection.filterMetadata('YEAR','equals',ano);
```

```
  var features = fcSelected.getInfo().features;
```

```
  for (var i=0;i<cartaslist.length; i++){
```

```
    var carta = cartaslist[i];
```

```
    var info = {carta1:getGridNameInfo(features,carta)};
```

```
    var carta_atual = gridFeatureCollection.filterMetadata('name', "equals", carta)
```

```
    var carta1 = mapBiomassDolt(info,carta_atual);
```

```
    switch (info.carta1.sensor){
```

```
      case "L8":
```

```
        var infocarta1 = {year:info.carta1.year, tag:{ref:info.carta1.tag.ref,
```

```
sma:info.carta1.tag.sma, ndfi:info.carta1.tag.ndfi, ndvi:info.carta1.tag.ndvi,
```

```
savi:info.carta1.tag.savi, evi2:info.carta1.tag.evi2, dt:info.carta1.tag.dt},
```

```

        vis:{ref:visParMedianL8, sma:visSMA, ndfi:visNDFI, DT:carta1.visDT},
color:info.carta1.color,
        gridName:info.carta1.gridname, download: info.carta1.download
    };
    break;
    default :
        print('O campo sensor possui um erro! Verifique se está escrito corretamente.');
```

```

    break;
}

var mapcarta1 = mapAddLayers(carta1, infocarta1);

}
}

//-----
// Dá ZOOM na região
//-----
//Map.centerObject(gridFeatureCollection, 9);

//-----
// Adicona o Grid
//-----

var blank = ee.Image(0).mask(0);
var outline = blank.paint(gridFeatureCollection, 'AA0000', 1);
var visPar = {'palette':'AA0000','opacity': 0.6};
Map.addLayer(outline, visPar, 'GRID 250mil');

//-----
// Add Bioma
//-----
var blank = ee.Image(0).mask(0);
var outline = blank.paint(biomaFeatureCollection, '000000', 2);
var visPar = {'palette':'000000','opacity': 0.7};
Map.addLayer(outline, visPar, 'Region', true);

```


Apêndice 3 – Tabela com data e hora de passagem do satélite em cada ponto órbita em cada cena para as cartas utilizadas no trabalho

PONTO/ÓRBITA	CARTA	DATA	HORA (GMT)	ELEVAÇÃO (graus)	AZIMUTE (graus)
217/66	SC-24-V-C	12/04/13	12:49:32	57,16	58,52
		28/04/13	12:49:31	54,70	49,72
		14/05/13	12:49:43	51,97	43,82
		30/05/13	12:49:48	49,59	40,66
		15/06/13	12:49:43	48,05	39,84
		01/07/13	12:49:42	47,69	40,93
		09/01/14	12:49:01	58,52	118,68
		25/01/14	12:48:51	58,28	112,20
		10/02/14	12:48:39	58,66	103,32
		26/02/14	12:48:26	59,16	92,41
		14/03/14	12:48:15	59,20	80,19
		30/03/14	12:47:58	58,31	67,96
		15/04/14	12:47:42	56,42	57,23
		01/05/14	12:47:28	53,84	49,05
		17/05/14	12:47:16	51,11	43,73
		02/06/14	12:47:21	48,87	40,96
		18/06/14	12:47:27	47,54	40,46
		04/07/14	12:47:33	47,41	41,81
		12/01/15	12:47:47	58,16	117,58
		28/01/15	12:47:41	58,06	110,72
		13/02/15	12:47:33	58,51	101,53
		01/03/15	12:47:30	58,98	90,40
		17/03/15	12:47:20	58,91	78,15
		02/04/15	12:47:07	57,88	66,12
		18/04/15	12:47:07	55,87	55,79
		04/05/15	12:46:54	53,21	48,03
		20/05/15	12:46:47	50,55	43,15
		05/06/15	12:46:55	48,45	40,80
		21/06/15	12:47:03	47,31	40,63
		16/02/16	12:47:39	58,64	99,64
03/03/16	12:47:38	59,07	88,23		
19/03/16	12:47:32	58,84	75,90		
04/04/16	12:47:23	57,62	64,05		

		20/04/16	12:47:17	55,47	54,12
		06/05/16	12:47:20	52,80	46,90
		22/05/16	12:47:21	50,23	42,43
		07/06/16	12:47:25	48,26	40,50
		23/06/16	12:47:31	47,31	40,67
		09/07/16	12:47:39	47,65	42,58
		25/07/16	12:47:44	49,33	45,93
		10/08/16	12:47:46	52,20	50,69
		12/04/13	12:49:56	56,22	56,88
		28/04/13	12:49:55	53,60	48,44
		14/05/13	12:50:07	50,78	42,81
		30/05/13	12:50:12	48,36	39,81
		15/06/13	12:50:07	46,81	39,06
		01/07/13	12:50:06	46,47	40,13
		09/01/14	12:49:24	58,99	116,46
		25/01/14	12:49:15	58,60	109,93
		10/02/14	12:49:03	58,75	100,97
		26/02/14	12:48:50	58,98	90,04
		14/03/14	12:48:39	58,72	77,95
		30/03/14	12:48:22	57,56	66,02
		15/04/14	12:48:06	55,45	55,66
		01/05/14	12:47:52	52,73	47,82
		17/05/14	12:47:40	49,92	42,75
217/67	SC-24-V-C	02/06/14	12:47:45	47,65	40,13
		18/06/14	12:47:51	46,30	39,68
		04/07/14	12:47:56	46,19	41,00
		12/01/15	12:48:11	58,61	115,37
		28/01/15	12:48:05	58,34	108,45
		13/02/15	12:47:57	58,56	99,19
		01/03/15	12:47:54	58,75	88,06
		17/03/15	12:47:43	58,39	75,96
		02/04/15	12:47:31	57,08	64,25
		18/04/15	12:47:31	54,87	54,29
		04/05/15	12:47:18	52,08	46,86
		20/05/15	12:47:11	49,35	42,21
		05/06/15	12:47:19	47,21	39,97
		21/06/15	12:47:27	46,07	39,85
		16/02/16	12:48:03	58,65	97,28
		03/03/16	12:48:01	58,78	85,89

		19/03/16	12:47:56	58,26	73,74
		04/04/16	12:47:47	56,78	62,23
		20/04/16	12:47:41	54,44	52,68
		06/05/16	12:47:44	51,65	45,77
		22/05/16	12:47:45	49,02	41,51
		07/06/16	12:47:49	47,02	39,69
		23/06/16	12:47:55	46,07	39,89
		09/07/16	12:48:03	46,43	41,74
		25/07/16	12:48:08	48,16	44,96
		10/08/16	12:48:10	51,11	49,50
		19/04/13	12:55:44	56,16	54,32
		05/05/13	12:55:45	53,50	46,78
		21/05/13	12:55:58	50,86	42,12
		06/06/13	12:55:58	48,79	40,04
		22/06/13	12:55:51	47,73	40,11
		16/01/14	12:55:04	58,32	116,16
		01/02/14	12:54:58	58,39	108,59
		17/02/14	12:54:45	58,90	98,76
		05/03/14	12:54:29	59,27	87,16
		21/03/14	12:54:19	58,94	74,75
		06/04/14	12:54:04	57,60	63,00
		22/04/14	12:53:48	55,35	53,30
		08/05/14	12:53:32	52,63	46,37
		24/05/14	12:53:25	50,05	42,21
218/66	SC-24-V-C	09/06/14	12:53:36	48,15	40,49
		25/06/14	12:53:38	47,32	40,84
		11/07/14	12:53:47	47,78	42,90
		03/01/15	12:53:57	58,58	120,28
		19/01/15	12:53:54	58,02	114,88
		04/02/15	12:53:51	58,21	106,96
		20/02/15	12:53:44	58,75	96,86
		08/03/15	12:53:36	59,05	85,11
		24/03/15	12:53:27	58,59	72,76
		09/04/15	12:53:17	57,11	61,32
		25/04/15	12:53:14	54,73	52,00
		11/05/15	12:52:58	52,01	45,56
		27/05/15	12:52:59	49,54	41,83
		12/06/15	12:53:11	47,81	40,48
		28/06/15	12:53:17	47,19	41,14

	07/02/16	12:53:56	58,34	105,28	
	23/02/16	12:53:49	58,87	94,83	
	10/03/16	12:53:47	59,08	82,87	
	26/03/16	12:53:38	58,44	70,56	
	11/04/16	12:53:32	56,78	59,40	
	27/04/16	12:53:28	54,33	50,61	
	13/05/16	12:53:27	51,64	44,61	
	29/05/16	12:53:34	49,27	41,30	
	14/06/16	12:53:37	47,70	40,34	
	30/06/16	12:53:45	47,29	41,31	
	16/07/16	12:53:53	48,22	43,88	
	01/08/16	12:53:56	50,45	47,84	
	19/04/13	12:56:08	55,13	52,84	
	05/05/13	12:56:09	52,36	45,63	
	21/05/13	12:56:22	49,64	41,20	
	06/06/13	12:56:22	47,55	39,23	
	22/06/13	12:56:15	46,49	39,33	
	16/01/14	12:55:28	58,73	113,92	
	01/02/14	12:55:22	58,62	106,28	
	17/02/14	12:55:09	58,88	96,39	
	05/03/14	12:54:53	58,96	84,82	
	21/03/14	12:54:43	58,34	72,62	
	06/04/14	12:54:28	56,74	61,22	
	22/04/14	12:54:12	54,31	51,89	
	08/05/14	12:53:56	51,48	45,27	
218/67	SC-24-V-C	24/05/14	12:53:49	48,84	41,31
		09/06/14	12:54:00	46,92	39,69
		25/06/14	12:54:02	46,09	40,06
		11/07/14	12:54:10	46,57	42,05
		03/01/15	12:54:21	59,10	118,07
		19/01/15	12:54:18	58,41	112,66
		04/02/15	12:54:15	58,40	104,67
		20/02/15	12:54:08	58,68	94,51
		08/03/15	12:54:00	58,69	82,81
		24/03/15	12:53:51	57,94	70,70
		09/04/15	12:53:41	56,22	59,61
		25/04/15	12:53:38	53,66	50,66
		11/05/15	12:53:22	50,84	44,50
		27/05/15	12:53:23	48,32	40,95

		12/06/15	12:53:35	46,57	39,68
		28/06/15	12:53:41	45,96	40,35
		07/02/16	12:54:20	58,49	102,95
		23/02/16	12:54:13	58,76	92,46
		10/03/16	12:54:11	58,66	80,59
		26/03/16	12:54:02	57,74	68,53
		11/04/16	12:53:55	55,84	57,75
		27/04/16	12:53:52	53,24	49,31
		13/05/16	12:53:51	50,45	43,58
		29/05/16	12:53:58	48,04	40,44
		14/06/16	12:54:01	46,45	39,55
		30/06/16	12:54:09	46,06	40,51
		16/07/16	12:54:16	47,03	42,99
		01/08/16	12:54:20	49,32	46,78
		19/04/13	12:56:56	53,01	50,19
		05/05/13	12:56:57	50,01	43,59
		21/05/13	12:57:10	47,18	39,55
		06/06/13	12:57:10	45,04	37,79
		22/06/13	12:57:03	43,99	37,94
		08/07/13	12:57:06	44,28	39,61
		24/07/13	12:57:05	45,99	42,52
		01/02/14	12:56:10	58,91	101,60
		17/02/14	12:55:56	58,66	91,70
		05/03/14	12:55:41	58,17	80,33
		21/03/14	12:55:31	56,98	68,64
		06/04/14	12:55:16	54,92	57,97
218/69	SD-23-X-D	22/04/14	12:55:00	52,16	49,36
		08/05/14	12:54:44	49,13	43,30
		24/05/14	12:54:37	46,38	39,70
		09/06/14	12:54:48	44,42	38,26
		25/06/14	12:54:49	43,60	38,66
		11/07/14	12:54:58	44,14	40,54
		27/07/14	12:55:01	46,08	43,64
		03/01/15	12:55:09	59,96	113,44
		19/01/15	12:55:06	59,02	108,07
		04/02/15	12:55:03	58,61	100,02
		20/02/15	12:54:56	58,37	89,87
		08/03/15	12:54:47	57,81	78,43
		24/03/15	12:54:39	56,50	66,86

	09/04/15	12:54:29	54,34	56,50	
	25/04/15	12:54:26	51,46	48,23	
	11/05/15	12:54:10	48,46	42,60	
	27/05/15	12:54:11	45,83	39,38	
	12/06/15	12:54:23	44,06	38,27	
	28/06/15	12:54:29	43,46	38,93	
	06/01/16	12:55:11	59,79	112,60	
	22/01/16	12:55:12	58,95	106,72	
	07/02/16	12:55:07	58,60	98,27	
	23/02/16	12:55:00	58,34	87,82	
	10/03/16	12:54:59	57,66	76,25	
	26/03/16	12:54:50	56,20	64,79	
	11/04/16	12:54:43	53,89	54,75	
	27/04/16	12:54:40	51,00	46,99	
	13/05/16	12:54:39	48,04	41,76	
	29/05/16	12:54:46	45,54	38,91	
	14/06/16	12:54:49	43,94	38,15	
	30/06/16	12:54:57	43,57	39,08	
	19/04/13	12:57:20	51,92	49,00	
	05/05/13	12:57:20	48,82	42,67	
	21/05/13	12:57:34	45,93	38,82	
	06/06/13	12:57:34	43,77	37,15	
	22/06/13	12:57:26	42,72	37,32	
	08/07/13	12:57:30	43,03	38,95	
	24/07/13	12:57:29	44,78	41,76	
	01/02/14	12:56:34	58,96	99,24	
	17/02/14	12:56:20	58,46	89,40	
	05/03/14	12:56:05	57,69	78,19	
218/70	SD-23-X-D	21/03/14	12:55:55	56,24	66,80
		06/04/14	12:55:40	53,96	56,49
		22/04/14	12:55:24	51,05	48,23
		08/05/14	12:55:08	47,93	42,42
		24/05/14	12:55:01	45,13	38,99
		09/06/14	12:55:12	43,16	37,63
		25/06/14	12:55:13	42,34	38,04
		11/07/14	12:55:22	42,90	39,87
		27/07/14	12:55:25	44,88	42,85
		03/01/15	12:55:33	60,31	111,04
		19/01/15	12:55:30	59,23	105,72

04/02/15	12:55:27	58,62	97,69
20/02/15	12:55:19	58,12	87,61
08/03/15	12:55:11	57,29	76,35
24/03/15	12:55:03	55,72	65,09
09/04/15	12:54:53	53,35	55,09
25/04/15	12:54:50	50,33	47,14
11/05/15	12:54:34	47,24	41,76
27/05/15	12:54:35	44,58	38,68
12/06/15	12:54:47	42,79	37,64
28/06/15	12:54:53	42,20	38,30
06/01/16	12:55:35	60,12	110,19
22/01/16	12:55:36	59,13	104,36
07/02/16	12:55:31	58,57	95,93
23/02/16	12:55:24	58,04	85,56
10/03/16	12:55:22	57,09	74,20
26/03/16	12:55:14	55,38	63,07
11/04/16	12:55:07	52,87	53,40
27/04/16	12:55:04	49,85	45,96
13/05/16	12:55:03	46,81	40,95
29/05/16	12:55:10	44,28	38,23
14/06/16	12:55:12	42,66	37,52
30/06/16	12:55:21	42,31	38,45

APÊNDICE 4 – Tabela com informações da espessura óptica do aerossol e coeficiente de Angstrom para os pontos e suas respectivas datas

PONTO	DATA	AOT	ANGSTROM
217	12/04/13	0,059	0,838
	28/04/13	0,097	0,384
	14/05/13	0,038	0,056
	30/05/13	0,039	0,875
	15/06/13	0,033	0,465
	01/07/13	0,03	0,778
	09/01/14	0,066	0,962
	25/01/14	0,172	0,872
	10/02/14	0,047	0,87
	26/02/14	0,068	0,585
	14/03/14	0,116	0,413
	30/03/14	0,1	0,908
	15/04/14	0,108	0,748
	01/05/14	0,175	0,545
	17/05/14	0,095	1,203
	02/06/14	0,09	1,228
	18/06/14	0,037	1,635
	04/07/14	0,048	1,035
	12/01/15	0,094	0,931
	28/01/15	0,172	1,194
	13/02/15	0,162	0,794
	01/03/15	0,144	0,703
	17/03/15	0,196	0,724
	02/04/15	0,109	0,729
	18/04/15	0,056	0,971
	04/05/15	0,081	0,477
	20/05/15	0,063	0,77
	05/06/15	0,074	0,475
	21/06/15	0,056	0,824
	16/02/16	0,234	0,184

	03/03/16	0,383	0,321
	19/03/16	0,383	0,321
	04/04/16	0,052	1,122
	20/04/16	0,109	0,277
	06/05/16	0,049	0,78
	22/05/16	0,039	0,719
	07/06/16	0,074	0,582
	23/06/16	0,058	0,429
	09/07/16	0,059	0,826
	25/07/16	0,062	0,408
	10/08/16	0,065	0,998
218	19/04/13	0,57	(-) 0,064
	05/05/13	0,05	0,719
	21/05/13	0,066	0,021
	06/06/13	0,056	0,345
	22/06/13	0,036	0,384
	08/07/13	0,043	0,276
	24/07/13	0,028	0,488
	16/01/14	0,089	0,67
	01/02/14	0,055	0,734
	17/02/14	0,087	1,312
	05/03/14	0,191	0,5
	21/03/14	0,098	0,976
	06/04/14	0,115	1,179
	22/04/14	0,065	0,904
	08/05/14	0,084	0,955
	24/05/14	0,133	0,717
	09/06/14	0,044	0,712
	25/06/14	0,049	0,943
	11/07/14	0,071	0,574
	27/07/14	0,069	0,883
	03/01/15	0,158	0,889
	19/01/15	0,135	1,116
	04/02/15	0,828	0,393
	20/02/15	0,08	0,749
	08/03/15	0,142	0,459
	24/03/15	0,171	0,724
	09/04/15	0,092	0,487

25/04/15	0,148	0,589
11/05/15	0,071	0,844
27/05/15	1,015	(-) 0,132
12/06/15	0,049	0,578
28/06/15	0,052	0,966
06/01/16	1,119	0,311
22/01/16	0,643	0,311
07/02/16	0,234	0,184
23/02/16	0,276	0,184
10/03/16	0,383	0,321
26/03/16	0,09	1,332
11/04/16	0,1	1,191
27/04/16	0,083	0,672
13/05/16	0,099	0,94
29/05/16	0,03	1,164
14/06/16	0,038	0,779
30/06/16	0,059	0,495
16/07/16	0,047	0,652
01/08/16	0,049	0,798
