



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

sid.inpe.br/mtc-m21c/2018/04.26.18.25-TDI

**USO DE DADOS DO SENSOR MSI/SENTINEL-2 E DE  
LIDAR AEROTRANSPORTADO PARA MAPEAMENTO  
DE FITOFISIONOMIAS DE CAATINGA E ESTUDO  
DAS RELAÇÕES COM ATRIBUTOS FÍSICO-QUÍMICOS  
DOS SOLOS**

Hilton Luís Ferraz da Silveira

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Lênio Soares Galvão, e  
Ieda Del'Arco Sanches, aprovada  
em 29 de maio de 2018.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/3R26CMH>

INPE  
São José dos Campos  
2018

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

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

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

**Membros:**

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

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

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

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

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

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

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

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

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

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

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

**EDITORAÇÃO ELETRÔNICA:**

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

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



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

sid.inpe.br/mtc-m21c/2018/04.26.18.25-TDI

**USO DE DADOS DO SENSOR MSI/SENTINEL-2 E DE  
LIDAR AEROTRANSPORTADO PARA MAPEAMENTO  
DE FITOFISIONOMIAS DE CAATINGA E ESTUDO  
DAS RELAÇÕES COM ATRIBUTOS FÍSICO-QUÍMICOS  
DOS SOLOS**

Hilton Luís Ferraz da Silveira

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Lênio Soares Galvão, e  
Ieda Del'Arco Sanches, aprovada  
em 29 de maio de 2018.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/3R26CMH>

INPE  
São José dos Campos  
2018

Dados Internacionais de Catalogação na Publicação (CIP)

---

Silveira, Hilton Ferraz da.  
Si39u      Uso de dados do sensor MSI/Sentinel-2 e de LiDAR  
aerotransportado para mapeamento de fitofisionomias de Caatinga  
e estudo das relações com atributos físico-químicos dos  
solos / Hilton Luís Ferraz da Silveira. – São José dos Campos :  
INPE, 2018.  
xx + 116 p. ; (sid.inpe.br/mtc-m21c/2018/04.26.18.25-TDI)

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

Orientadores : Drs. Lênio Soares Galvão, e Ieda Del’Arco  
Sanches.

1. Caatinga. 2. Random Forest. 3. Análise por componentes  
principais. 4. LiDAR. 5. Solos. I.Título.

CDU 528.8:581.5

---



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

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



Aluno (a): **Hilton Luís Ferraz de Silveira**

Título: "USO DE DADOS DO SENSOR MSI/SENTINEL-2 E DE LIDAR AEROTRANSPORTADO PARA MAPEAMENTO DE FITOFISIONOMIAS DE CAATINGA E ESTUDO DAS RELAÇÕES COM ATRIBUTOS FÍSICO-QUÍMICOS DOS SOLOS"

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

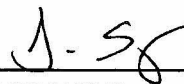
Dr. Flávio Jorge Ponzoni



Presidente / INPE / SJC Campos - SP

( ) Participação por Vídeo - Conferência

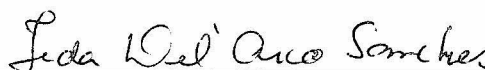
Dr. Lênio Soares Galvão



Orientador(a) / INPE / SJC Campos - SP

( ) Participação por Vídeo - Conferência

Dra. Ieda Del' Arco Sanches



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

( ) Participação por Vídeo - Conferência

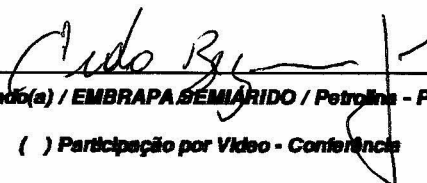
Dr. Antônio Roberto Formaggio



Membro da Banca / INPE / SJC Campos - SP

( ) Participação por Vídeo - Conferência

Dr. Iedo Bezerra Sá



Convidado(a) / EMBRAPA SEMÁRIDO / Petrolina - PE

( ) Participação por Vídeo - Conferência

Este trabalho foi aprovado por:

( ) maioria simples

(x) unanimidade

São José dos Campos, 29 de maio de 2018



## **AGRADECIMENTOS**

Agradeço aos meus orientadores Dr. Lênio Soares Galvão e Dra Ieda Del'Arco Sanches pela orientação, paciência e apoio dispensados a mim durante todo o curso.

Aos meus colegas da Embrapa Dr. Iedo Bezera Sá e Dra. Tatiana Ayako Taura, pelo apoio durante os trabalhos de campo e ao Dr. Waldir de Carvalho Junior, por ter aceitado ser meu Conselheiro Acadêmico junto a Embrapa.

À minha família, de maneira especial à minha querida esposa, Fernanda, aos meus filhos Laura e Luís Carlos, aos meus pais, Edinéia Munhoz e Antônio Carlos Ferraz da Silveira, aos meus avós, tios, primos e afilhados pelo carinho e apoio nesta jornada, sem os quais jamais teria conseguido chegar até aqui.

Aos meus colegas de Embrapa Solos Ademir B. Silva, Alexandre H. C. Barros, André J. do Amaral, Carlos A de Oliveira, Carmem L. V. da Silva, Davi F. da Silva, Flávio A. Marques, José C. de Araújo Filho, José C. P. dos Santos, Josué F. da Silva Júnior, Lucia Raquel Q. P. da Luz, Luciano J. de O. Accioly, Manoel B. de Oliveira Neto, Maria de Lourdes M. S. Brefin, Maria Sônia L. da Silva, Paulo C. de Lima e Ricardo de O. Dart pelo incentivo à minha candidatura ao mestrado.

A todos os meus colegas de curso, em especial Bruno Montibeller (meu fivéio), Alindomar L. Silva, Mikhaela A. J. S. Pletsch, Maria P. da Silva, Anderson Jorge, Clarissa A. K. Endo, Erone G. dos Santos, Raquel R. de Oliveira, Denis C. Vieira e Victor H. R. Prudente, e aos meus colegas de sala 51 do ASA Vitor Martins, Daniel A. Maciel, Rogério Flores Júnior e Caroline T. Cairo pela amizade e companheirismo ao longo desta caminhada.

Agradeço finalmente às equipes das bibliotecas da Embrapa Solos, da Embrapa Semiárido e do INPE pela busca de documentos e pela revisão do documento final.



## RESUMO

A Caatinga, vegetação natural adaptada às condições do semiárido brasileiro, possui fitofisionomias variadas de difícil mapeamento, cuja distribuição é influenciada pelas características pluviométricas e pedológicas locais. No presente estudo, testou-se o potencial de dados multi-temporais do sensor MSI/Sentinel-2, obtidos em quatro datas de 2015 a 2016 (período chuvoso e seco), juntamente com observações LiDAR, para o mapeamento de sete fitofisionomias da Caatinga. A área de estudo está localizada no Estado de Pernambuco. Usando um mapa de referência da vegetação e o classificador *Random Forest* (RF), avaliou-se, em primeiro lugar, a capacidade do MSI/Sentinel-2 em mapear fitofisionomias de Caatinga e os eventuais ganhos na classificação decorrentes do uso de dados multi-temporais sobre dados mono-temporais (período chuvoso ou seco); do uso de índices de vegetação sobre dados de reflectância; e da incorporação de métricas derivadas de dados LiDAR. Estudou-se também a existência de possíveis relações espaciais entre a vegetação mapeada por RF e 20 atributos físico-químicos determinados de 75 perfis de solos, que foram submetidos à Análise por Componentes Principais (ACP) e procedimentos de krigagem. Os resultados mostraram que: não há diferenças entre as classificações dos períodos seco e chuvoso; classificações com dados multi-temporais são superiores às que utilizam apenas dados mono-temporais; os índices de vegetação, por resultarem em classificações semelhantes aos dados de reflectância, podem substituir estes últimos com menor volume de dados; dados LiDAR melhoram a classificação das classes arbórea aberta (Aa) em 11,1%, das arbórea rala (Ar) em 18,5% e das subarbustivas (S) em 10,7%. Foram encontradas diferenças estatisticamente significativas entre os atributos do solo carbono orgânico, capacidade de troca catiônica, capacidade de campo, profundidade do solo, porosidade e % de terra fina, cascalho e calhau entre fitofisionomias arbóreas e subarbustivas.

Palavras chave: Caatinga. Fitofisionomias. Random Forest. Sentinel-2. Análise por componentes principais. LiDAR. Solos.



# **USE OF MSI/SENTINEL-2 AND AIRBORNE LIDAR DATA FOR MAPPING CAATINGA PHYTOPHYSIOGNOMIES AND STUDYING THEIR RELATIONSHIPS WITH PHYSICO-CHEMICAL ATTRIBUTES OF SOILS**

## **ABSTRACT**

Caatinga is a natural semi-arid vegetation type, which occupies great part of northeastern region of Brazil. This ecosystem contains a variety of phytophysionomies of difficult mapping with their occurrence influenced by local rainfall and soil attributes. This work verified the potential use of multi-temporal data from the MSI/Sentinel-2, obtained in four dates between 2015 and 2016 (rainy to dry seasons), along with LiDAR observations, for mapping seven Caatinga's phytophysionomies in a study area located in the state of Pernambuco. Using a vegetation reference map and Random Forest (RF) classification, eventual gains in classification accuracy have been evaluated from multi-temporal over mono-temporal MSI data (rainy and dry seasons); from adding vegetation indices into the analyses; and from inserting LiDAR metrics into the classification. The relationships between the mapped vegetation by RF and 20 physico-chemical attributes of 75 soil profiles were studied by using principal component analysis (PCA) and ordinary kriging. The results showed that: (a) there were no differences in classification accuracy between the dry and rainy seasons; (b) multi-temporal data improved classification accuracy compared to mono-temporal observations; (c) a smaller number of vegetation indices had similar classification performance than a greater number of reflectance of bands; and (d) LiDAR metrics improved classification accuracy of arboreous and sub-shrub classes (11,1% and 10,7% respectively). Statistically significant differences were observed in organic carbon content, cation exchange capacity, water retention at field capacity, horizon thickness, soil porosity and rock fragments (% pebble, gravel, fine-earth fraction) between these two types of phytophysionomies (arboreous and sub-shrub classes). Key words: Caatinga.

Phytophysionomies. Random Forest. Sentinel-2. Principal component analysis.  
LiDAR. Soils.



## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 3.1 – Localização da área de estudo: a) mapa do Brasil com a área do semiárido; b) posição da área de estudo na região semiárida; c) composição MSI/Sentinel-2 do dia 14/05/2016, e d) composição MSI/Sentinel-2 do dia 22/08/2016. Em (c) e (d), as bandas de 842 nm(R), 665 nm (G) e 2190nm (B) foram utilizadas na composição colorida.....	27
Figura 3.2 - Precipitação acumulada mensal em mm para o período de dezembro de 2015 a agosto de 2016 com o quintil mensal da precipitação baseada na série histórica de 1975 a 2015.....	29
Figura 3.3 - Mapa de solos e localização dos 75 perfis amostrados no Campo Experimental da Embrapa Semiárido, Petrolina (PE).....	32
Figura 4.1 – Fluxograma das etapas realizadas neste trabalho. ....	34
Figura 4.2 - Exemplo de projeção do pixel de 20x20 metros do Sentinel-2 sobre o MDD com resolução de 1x1 metro mostrando duas árvores com alturas próximas à 7 metros (uma no topo e outra na base da figura) intercalada por vegetação de menor porte.....	40
Figura 5.1 - Mapa de referência da vegetação da área de estudo, obtido a partir de fotografias aéreas e de atividades de campo. ....	48
Figura 5.2 - Perfis LiDAR obtidos sobre as principais fitofisionomias de Caatinga da área de estudo, em um transecto de 100 m para as fitofisionomias arbórea (A), arbórea-arbustiva (AA) e subarbustiva (S). ....	49
Figura 5.3 - Representação das fitofisionomias existentes na área de estudo: Arbórea aberta (Aa), Arbórea rala (Ar), Arbórea-arbustiva densa (AAAd), Arbórea-arbustiva aberta (AAa), Arbórea-arbustiva rala (AAr), Arbustiva (B) e Subarbustiva (S). ....	50
Figura 5.4 - Composições coloridas 842 nm (R), 1610 nm (G) e 665 nm (B) para as datas: a) 26/12/2015; b) 14/05/2016; c) 13/07/2016, e; d) 22/08/2016. ....	51

Figura 5.5 – Reflectância dos principais grupos de fitofisionomias de Caatinga da área de estudo, medida pelo sensor MSI/Sentinel-2 nos períodos chuvoso (a) e seco (b). Para facilitar a representação gráfica, o desvio padrão é apresentado apenas para a Caatinga arbórea. ..	52
Figura 5.6 - Comportamento sazonal dos principais grupos de fitofisionomias de Caatinga para os índices de vegetação OSAVI <sub>[705, 750]</sub> (a), NDII1 (b) e NDVI (c), calculados em quatro datas de aquisição das imagens MSI/Sentinel-2. A precipitação de dezembro de 2015 a agosto de 2016 é apresentada (barras hachuradas) e comparada com médias mensais históricas (1975-2015) (barras pontilhadas). Para facilitar a representação gráfica, o desvio padrão é apresentado apenas para a Caatinga arbórea.....	53
Figura 5.7 – Classificação <i>Random Forest</i> usando os dados de reflectância do período: a) chuvoso - 14/05/2016 (Estratégia I) e b) seco - agosto de 2016 (Estratégia II).....	55
Figura 5.8 – Classificação RF baseada nos dados de reflectância das quatro datas (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016), conforme estratégia III.....	57
Figura 5.9 – Ranqueamento das vinte principais métricas para o processo de classificação da estratégia III com base no <i>Mean Decrease Impurity</i> (MDI). .....	58
Figura 5.10 - Diagrama de espalhamento das métricas com melhor ranqueamento pelo <i>Random Forest</i> , considerando a abordagem multi-temporal com dados de reflectância do MSI/Sentinel-2.....	59
Figura 5.11 - Gráfico com os valores de exatidão do usuário para as classificações RF usando dados de reflectância dos períodos chuvoso (Estratégia I) e seco (Estratégia II) e de todas as quatro datas de aquisição das imagens MSI/Sentinel-2 (Estratégia III). ..	59
Figura 5.12 – Classificação RF com a) índices de vegetação multi-temporais (Estratégia IV) e com a combinação de b) dados de reflectância e	

índices de vegetação multi-temporais do sensor MSI/Sentinel-2 (Estratégia V). .....	60
Figura 5.13 - Importância das métricas para classificação utilizando todos os dados de reflectância e todos os índices de vegetação (Estratégia V) com base no <i>Mean Decrease Impurity</i> (MDI). .....	62
Figura 5.14 - Diagrama de espalhamento dos índices de vegetação NDWI e EVI, ambos para o dia 26/12/2015.....	63
Figura 5.15 - Gráfico com os valores de exatidão do usuário para as classificações usando os dados de reflectância (Estratégia III), os índices de vegetação (Estratégia IV) e utilizando os dados de reflectância e os índices (Estratégia V). .....	63
Figura 5.16 – Classificação RF usando dados multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 e métricas LiDAR (Estratégia VI). .....	64
Figura 5.17 - Importância das métricas multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 e das métricas LiDAR para classificação RF (Estratégia VI) com base no <i>Mean Decrease Impurity</i> (MDI).....	66
Figura 5.18 - Diagrama de espalhamento com os valores das métricas de EVI e de porcentagem de indivíduos arbóreos. ....	66
Figura 5.19 - Gráfico com os valores de acurácia do usuário para a classificação RF usando dados multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 (Estratégia V) e a combinação destes dados com métricas LiDAR (Estratégia VI). .....	67
Figura 5.20 – Mapas de confiança de acordo com a porcentagem de votos na classe eleita para as classificações RF da a) estratégia I e b) estratégia VI. ....	68
Figura 5.21 - Diagramas de espalhamento para as relações entre o teor de argila e a umidade dos solos em (a) e entre o CTC e o conteúdo de carbono orgânico em (b). .....	70
Figura 5.22 – Porcentagem de variância retida pelas componentes principais.	71

Figura 5.23 - Gráficos de autovetores dos 20 atributos físico-químicos dos solos nas três primeiras componentes principais. ....	72
Figura 5.24 - Escores das duas primeiras componentes principais resultantes da ACP aplicada 20 atributos físico-químicos de 75 perfis de solos. ....	72
Figura 5.25 - Semivariogramas experimentais e teóricos para as PC1 (a), PC2 (b) e, PC3 (c).....	73
Figura 5.26 - Mapas interpolados por meio da krigagem: a) primeira componente; b) CTC; c) VS e; d) CC.....	74
Figura 5.27 - Mapas interpolados por meio da krigagem: a) segunda componente; b) saturação por alumínio; c) VV e; d) pH em água. ....	74
Figura 5.28 - Mapas interpolados por meio da krigagem: a) terceira componente; b) % de cascalho; c) % de terra fina e; d) VV.....	74
Figura 5.29 – Vista em 3D das distribuições espaciais dos principais atributos relacionados à PC1: a) classificação RF referente à estratégia VI sobre o MDT, b) CTC, c) soma de bases, d) capacidade de campo, e) saturação por $Al^{+++}$ , f) saturação por bases, g) ponto de murcha permanente, h) % de calhaus, i) % de cascalho, e j) % de terra fina. ....	75
Figura 5.30 - Box-plot das distribuições dos atributos dos solos a) Carbono orgânico, b) CTC, c) CC, d) saturação por $Al^{+++}$ , e) profundidade do solo, f) terra fina, g) cascalho, h) calhaus, i) PMP e, j) porosidade para as fitofisionomias arbóreas (A), arbustivas (B) e subarbustivas (S). As letras abaixo do gráfico indicam a classe pertencente do box-plot, enquanto que as letras acima indicam a classe com a qual existe igualdade a 5% de significância estatística.....	77

## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Características espectrais e espaciais do sensor MSI/Sentinel-2A. .....	17
Tabela 2.2 - Características espectrais e espaciais do sensor MSI/Sentinel-2B. .....	18
Tabela 3.1 – Número de indivíduos por hectare obtidos por levantamentos florísticos realizados na área de estudo, onde I, II, III e IV correspondem respectivamente aos estudos de Drumond et al. (2000), Albuquerque e Bandeira (1995), Calixto Júnior e Drumond (2011) e Alves et al. (2017). ....	30
Tabela 4.1 - Estratificação vertical para fitofisionomias de Caatinga. ....	35
Tabela 4.2 - Estratificação horizontal para fitofisionomias de Caatinga. ....	35
Tabela 4.3 - Imagens MSI/Sentinel-2 livres de nuvens disponíveis para a área de estudo, com suas respectivas geometrias de iluminação. ....	36
Tabela 4.4 - Índices de vegetação considerados no estudo. Os comprimentos de onda nas equações correspondem aos centros das bandas (nm) do MSI/Sentinel-2A. ....	38
Tabela 4.5 - Métricas LiDAR consideradas neste trabalho. ....	41
Tabela 5.1 – Duas métricas LiDAR utilizadas neste trabalho, onde hVeg é a altura média da vegetação e stdVeg é o desvio padrão da altura. ....	49
Tabela 5.2 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação RF no período chuvoso (Estratégia I). ....	55
Tabela 5.3 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação RF no período seco (Estratégia II). ....	56

Tabela 5.4 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação multi-temporal com dados de reflectância do sensor MSI/Sentinel-2 (Estratégia III). .....	57
Tabela 5.5 - Matriz de confusão para a classificação RF utilizando índices de vegetação multi-temporais (Estratégia IV). .....	61
Tabela 5.6 - Matriz de confusão para a classificação RF utilizando a combinação de dados multi-temporais de reflectância e índices de vegetação (Estratégia V). .....	61
Tabela 5.7 - Matriz de confusão da classificação RF, utilizando os atributos reflectância, índice de vegetação e LiDAR.....	65
Tabela 5.8 - Matriz de correlação de Pearson dos atributos físico-químicos de 75 perfis de solos. As melhores correlações são destacadas em negrito. Os sinais + e # indicam significância a 1% e 5%, respectivamente. ....	69

## LISTA DE SIGLAS E ABREVIATURAS

%A	- Porcentagem de cobertura arbórea em 400m <sup>2</sup>
%AA	- Porcentagem de cobertura arbórea-arbustiva em 400m <sup>2</sup>
%B	- Porcentagem de cobertura arbustiva em 400m <sup>2</sup>
%GL	- Porcentagem de cobertura gramínea-lenhosa em 400m <sup>2</sup>
%S	- Porcentagem de cobertura subarbustiva em 400m <sup>2</sup>
A	- Arbórea
Aa	- Arbórea aberta
AA	- Arbórea-Arbustiva
AAa	- Arbórea-Arbustiva aberta
AAd	- Arbórea-Arbustiva densa
AAr	- Arbórea-Arbustiva rala
ACP	- Análise por Componentes Principais
ADS	- Airborne Digital Sensor
ALS	- Airborne Laser Scanning
Ar	- Arbórea rala
ARVI	- Atmospherically Resistant Vegetation Index
B	- Arbustiva
CASI	- Compact Airborne Spectrographic Imager
CC	- Capacidade de Campo
CHRIS	- Compact High Resolution Imaging Spectrometer
CP	- Componentes Principais
CPATSA	- Centro de Pesquisa Agropecuária do Trópico Semiárido
CTC	- Capacidade de Troca Catiônica
Curv	- Curvatura do terreno calculada a partir do MDT
Decl	- Declividade do terreno calculada a partir do MDT
EG	- Exatidão global
EI	- Erros de inclusão
EO	- Erros de omissão
EP	- Exatidão do produtor
ESA	- European Space Agency
ETM+	- Enhanced Thematic Mapper Plus
EU	- Exatidão do usuário
EVI	- Enhanced Vegetation Index
GMES	- Global Monitoring for Environment and Security
hVegMax	- Altura máxima da vegetação
hVegMed	- Altura média da vegetação
hVegSTD	- Desvio padrão das alturas da vegetação
IAF	- Índice de Área Foliar

IDE	- Integrated Development Environment
ITEP	- Instituto de Tecnologia de Pernambuco
IV	- Índices de vegetação
KMO	- Kaiser-Meyer-Olkin
LiDAR	- Light Detection And Ranging
LUT	- Look-up tables
MDD	- Modelo Digital do Dossel
MDE	- Modelo Digital de Elevação
MDT	- Modelo Digital do Terreno
MODIS	- Moderate Resolution Imaging Spectroradiometer
MSA	- Measure of Sampling Adequacy
MSI	- MultiSpectral Instrument
NDII	- Normalized Difference Infrared Index
NDVI	- Normalized Difference Vegetation Index
NIR	- Infravermelho próximo
OMI	- Ozone Monitoring Instrument
OSAVI	- Optimized Soil-Adjusted Vegetation Index
PCA	- Principal Component Analysis
PE3D	- Pernambuco Tridimensional
PEC	- Padrão de Exatidão Cartográfica
PMP	- Ponto de Murcha Permanente
RD	- Razão de dependência espacial
RF	- Random Forest
S	- Subarrestiva
Sen2Cor	- Sentinel-2 Atmospheric Correction
SIRGAS	- Sistema de Referência Geocêntrico para as Américas
SRHE	- Secretaria de Recursos Hídricos e Energéticos
SVM	- Support Vector Machine
SWIR	- Infravermelho de ondas curtas
TM	- Thematic Mapper
UE	- União Europeia
UTM	- Universal Transversa de Mercator
VIS	- Visível
VS	- Soma de bases
VV	- Saturação por bases



## SUMÁRIO

	<b><u>Pág.</u></b>
1 INTRODUÇÃO.....	1
1.1. Hipótese.....	6
1.2. Objetivos.....	6
2 FUNDAMENTAÇÃO TEÓRICA .....	8
2.1. Estudos de sensoriamento remoto no ecossistema da Caatinga .....	8
2.1.1. Vegetação .....	9
2.1.2. Solos .....	11
2.1.3. Interação vegetação-solo .....	11
2.2. Light Detection And Ranging (LiDAR).....	14
2.3. Sensor MSI/Sentinel-2 .....	16
2.4. Índices de vegetação (IVs) .....	19
2.5. Classificador Random Forest (RF).....	21
2.6. Análise por Componentes Principais (ACP) .....	22
2.7. Krigagem .....	24
3 ÁREA DE ESTUDO .....	27
4 MATERIAIS E MÉTODOS .....	34
4.1. Seleção da área de estudo .....	34
4.2. Estudo da Vegetação.....	34
4.2.1. Obtenção do mapa de referência (fotografias aéreas e atividades de campo) .....	34
4.2.2. Aquisição e pré-processamento das imagens MSI/Sentinel-2A ....	36
4.2.3. Reflectância e índices de vegetação.....	37
4.2.4. Aquisição e tratamento de dados LiDAR.....	39
4.2.5. Classificação Random Forest.....	41
4.3. Análise dos atributos físico-químicos do solo .....	44
4.3.1. Levantamento dos dados físicos e químicos do solo .....	44
4.3.2. Análise por componentes principais (ACP) .....	45
4.3.3. Krigagem .....	46

4.4. Relações entre solo e vegetação.....	47
5 RESULTADOS.....	48
5.1. Caracterização estrutural das fitofisionomias .....	48
5.2. Caracterização espectro-temporal das fitofisionomias.....	51
5.3. Classificação das fitofisionomias usando Random Forest.....	54
5.3.1. Classificações RF nas estações seca e chuvosa.....	54
5.3.2. Classificação mono-temporal versus multi-temporal.....	56
5.3.3. Classificação RF com índices de vegetação.....	60
5.3.4. Adição de métricas LiDAR na classificação .....	63
5.4. Análise por componentes principais (ACP) dos atributos físico-químicos dos solos e espacialização por krigagem.....	68
5.5. Análise da relação entre solo e vegetação .....	75
6 DISCUSSÃO.....	78
6.1. Mapeamento da Caatinga.....	78
6.2. Análise dos solos.....	85
6.3. Relações entre atributos físico-químicos do solo e fitofisionomias de Caatinga.....	86
7 CONCLUSÃO.....	89
REFERÊNCIAS BIBLIOGRÁFICAS.....	91

## 1 INTRODUÇÃO

O semiárido brasileiro compreende 11,5% do território nacional e abriga 11,8% da população do Brasil (MEDEIROS et al., 2012). É caracterizado pelo baixo volume e pela alta variabilidade (espacial, temporal e volumétrica) de sua precipitação que, aliada a temperatura elevada, produz déficit hídrico em praticamente o ano todo (ARAÚJO FILHO et al., 2000).

A Caatinga, vegetação natural local adaptada a esta condição de aridez, possui fitofisionomias variadas e com elevado endemismo de fauna e flora (SÁ; SILVA, 2010; MORO et al., 2015). A falta de conhecimento a seu respeito, somado a uma ideia errônea que a associava a uma baixa biodiversidade, fez com que a região contasse com o menor número de unidades de conservação do país, quando comparado com as vegetações localizadas em outros ecossistemas (GIULIETTI et al., 2004; MINISTÉRIO DO MEIO AMBIENTE, 2012). Além disso, as unidades de conservação existentes não contemplam toda a variabilidade ambiental da Caatinga e a crescente conversão de seus remanescentes para pastagens e áreas agrícolas tem levado a um aumento no risco de desertificação e da perda da biodiversidade (MORO et al., 2015; ERASMI et al., 2014).

Outro ponto importante é que, uma vez que a pluviosidade da região é extremamente dependente dos processos oceânicos, o semiárido é considerado um dos domínios climáticos mais potencialmente afetados pelos efeitos das mudanças globais (BARBOSA et al., 2006). Portanto, parte da vegetação do semiárido tem alta vulnerabilidade, com severos riscos à sobrevivência de espécies, de comunidades e de linhagens vegetais (MORO et al., 2015).

Toda esta rica diversidade se organiza em fitofisionomias com densidade de vegetação e estrutura do dossel bastante distintas, mas com transições muitas vezes graduais de seus limites. Um dos primeiros trabalhos de classificação dos diversos tipos fitofisionômicos foi proposto por Andrade-Lima (1981), que descreveu cerca de doze tipos de Caatinga, formando unidades compostas por um ou mais destes tipos. Sampaio e Rodal (2000), numa tentativa de espacializar

as unidades/tipos propostas por Andrade-Lima (1981), promoveram a sua compatibilização com as unidades de paisagem e os geoambientes definidos por Silva et al. (1993). Entretanto, as diferenças entre as características e as escalas dos dois trabalhos não permitiram mapear mais detalhadamente as diversas fitofisionomias.

Outra característica importante da Caatinga é a relação entre as características pluviométricas e pedológicas na distribuição de espécies e de diversas fitofisionomias, reportadas por trabalhos como os de Andrade-Lima (1981); Santos et al. (1992); Ferraz et al. (2003); Silva, K. A. Da et al. 2009; Arruda (2012).

Na porção oeste do estado de Pernambuco, por exemplo, encontra-se a região conhecida popularmente como “sertão”, com maior deficiência hídrica e chuvas mais irregulares. Nesta região predomina a Caatinga hiperxerófila, constituída por diferentes fitofisionomias, desde formações arbustivas (cobertura vegetal do solo esparsa), em solos mais rasos e pedregosos, até formações arbóreas (cobertura vegetal densa), em solos mais bem desenvolvidos (SÁ; SILVA, 2010).

Uma vez que o ciclo sazonal da vegetação é regulado principalmente pela precipitação, propriedades do solo, como a textura, a profundidade e a pedregosidade, podem influenciar a ocorrência e a fenologia das espécies vegetais, por controlarem a disponibilidade de água e o desenvolvimento do sistema radicular das plantas. Este controle exercido pelos solos pode influenciar a distribuição espacial das fitofisionomias de Caatinga. Esta conjugação de fatores, portanto, torna o mapeamento dos tipos de vegetação no semiárido brasileiro um verdadeiro desafio.

Esta dificuldade é expressa pela inexistência de uma chave de classificação consolidada como ocorre, por exemplo, para o cerrado, com o trabalho de Ribeiro e Walter (1998). A proposição de Andrade-Lima (1981), ancorada primordialmente na concepção florística, dificulta sua aplicação em mapeamentos sistemáticos e em larga escala. Desta forma, a diversidade dos

padrões de vegetação e as inúmeras questões e lacunas não preenchidas dificultam a elaboração de um sistema de classificação ideal (GIULIETTI et al., 2004).

No estudo das fitofisionomias da Caatinga, o sensoriamento remoto tem um papel importante. Dependendo das resoluções espacial e espectral dos instrumentos ativos e passivos, seus dados podem ser úteis para observar alterações na estrutura do dossel, na composição bioquímica e na fisiologia das plantas, em decorrência dos efeitos sazonais do clima e das variações do substrato (MOORE et al., 2016). Além disso, o sensoriamento remoto é um meio efetivo de estender a interpretação das observações pontuais de campo sobre a distribuição das fitofisionomias e de suas relações com os solos para uma escala regional. Apesar destas vantagens, quando comparado com a Amazônia e o Cerrado, o número de estudos envolvendo dados de sensoriamento remoto na Caatinga é relativamente pequeno.

Recentemente, novos sensores multiespectrais têm sido planejados e lançados contendo melhorias nas resoluções espacial e espectral, quando comparadas às dos instrumentos da série Landsat. Um destes novos sensores é o *MultiSpectral Instrument* (MSI), a bordo dos satélites Sentinel-2A e Sentinel-2B, lançados respectivamente em junho de 2015 e em março de 2017, no contexto do programa GMES (*Global Monitoring for Environment and Security*). O principal objetivo da missão é melhorar o monitoramento da superfície terrestre usando treze bandas espectrais, distribuídas nas faixas do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR) (DRUSCH et al., 2012).

Destas treze bandas espectrais do MSI, duas estão situadas na faixa espectral que compreende a borda vermelha (690 a 760 nm). Esta faixa tem se revelado importante na avaliação de atributos biofísicos e bioquímicos da vegetação. Pesquisadores, por meio dos dados MSI/Sentinel-2 originais ou simulados a partir de sensores hiperespectrais, estimaram o índice de área foliar verde e o

conteúdo de clorofila (DELEGIDO et al., 2011; DONG et al., 2015), o índice de área foliar senescente (DELEGIDO et al., 2015), a biomassa (SIBANDA et al., 2015) e o conteúdo de nitrogênio foliar (CLEVERS; GITELSON, 2013; RAMOELO et al., 2015).

Para o estudo da Caatinga, as bandas da borda vermelha, do NIR e do SWIR, podem ser bastante interessantes, uma vez que estas bandas são capazes de indicar variações na estrutura da vegetação e na quantidade de vegetação não-fotossinteticamente ativa (ROBERTS et al., 1993; DELEGIDO et al., 2015). Esses atributos têm variação sazonal marcante no ambiente semiárido devido à presença de uma grande quantidade de espécies decíduas. Outro aspecto importante para o estudo da Caatinga, que diferencia o sensor MSI/Sentinel-2 de outros instrumentos da série Landsat, é a resolução espacial que varia de 10 a 20 metros para as suas principais bandas, contendo apenas 3 bandas com resolução de 60 metros voltadas para a correção atmosférica de suas imagens (DRUSCH et al., 2012). Estudos sobre o uso de dados do sensor MSI/Sentinel-2 ainda não foram reportados no ambiente da Caatinga, assim como não foram usados para entender as relações entre a distribuição da vegetação e os tipos de solos.

Apesar da capacidade dos sensores ópticos multiespectrais passivos para mapear variações na densidade de cobertura vegetal ou na estrutura horizontal dos dosséis, eles apresentam limitações para caracterizar a estrutura vertical da vegetação quando comparados com os sensores ativos LiDAR (*Light Detection And Ranging*). Os instrumentos LiDAR podem quantificar as dimensões verticais e volumétricas da estrutura da vegetação (BERGEN et al., 2009). Como resultado deste poder de quantificação, diversos trabalhos surgem todos os anos, com novas aplicações para os dados LiDAR, como, por exemplo, o mapeamento e a caracterização de espécies arbustivas (MUNDT et al., 2006; VIERLING et al., 2012); a caracterização de habitats para vida selvagem (GARCIA-FECED et al., 2011); e o cálculo da biomassa acima do solo (HICKEY et al., 2018). Para o mapeamento das fitofisionomias de Caatinga, no entanto, o

uso potencial do LiDAR ainda não foi devidamente caracterizado pela escassez de dados na região e pelo fato desta tecnologia ser mais útil para a caracterização da estrutura vertical de florestas tropicais da Amazônia.

A maioria dos estudos de sensoriamento remoto da Caatinga tem utilizado dados da série Landsat de sensores em observações mono-temporais, geralmente submetidos a classificadores convencionais, como os de máxima verossimilhança, como por exemplo nos trabalhos de Silva e Santos (2011), Coelho et al. (2014) e Fernandes et al. (2015). Não há registros sobre investigações que tenham utilizado o conjunto de dados multi-temporais para fins de classificação, focando-se principalmente na classificação mono-temporal do período seco, uma vez que a alta frequência de nuvens ao longo de boa parte do ano dificulta a obtenção de imagens no período chuvoso (SILVEIRA et al., 2017).

Neste contexto, o uso de classificadores como *Random Forest* é bastante interessante, considerando a existência de observações multi-temporais do MSI/Sentinel-2 sobre a Caatinga e a possibilidade do uso combinado de dados LiDAR disponíveis. Quando comparado com os classificadores convencionais, o *Random Forest* tem a vantagem de conseguir lidar com a elevada variância temporal da reflectância da vegetação; possuir uma alta velocidade de processamento; necessitar de poucos parâmetros a serem definidos pelo usuário; dispor de pouca sensibilidade à dimensão do conjunto de treinamento e ao tamanho das classes; resultar em elevada acurácia de classificação; e indicar a importância de cada variável na classificação (RODRIGUEZ-GALIANO et al., 2012; MÜLLER et al., 2015; CLARK; KILHAM, 2016).

Inserida no sertão, na microrregião de Petrolina, o campo experimental da Embrapa Semiárido e o seu entorno constituem excelente área de estudo. Contam com uma vegetação preservada, especialmente no campo experimental, representativa das fitofisionomias de Caatinga presentes naquela porção do Nordeste. Além disso, parte do campo experimental conta com

levantamento detalhado de solos, feito por Burgos e Cavalcanti (1990), com 75 perfis de solos com análises associadas de atributos físico-químicos.

Visto que quatro imagens do MSI/Sentinel-2, livres de cobertura de nuvens, foram obtidas recentemente sobre a região, o uso destes dados constitui uma boa oportunidade para se testar o potencial da reflectância de suas bandas e de alguns índices de vegetação para o estudo da Caatinga. Somado a isso, o estado de Pernambuco foi recentemente recoberto por um levantamento LiDAR, (Projeto Pernambuco 3D), fornecendo algumas métricas potenciais para avaliação do potencial de mapeamento de suas fitofisionomias.

### **1.1. Hipótese**

Desta forma, admite-se a hipótese de que existe associação entre os atributos físico-químicos, medidos em Argissolos Vermelho-Amarelo do campo experimental da Embrapa Semiárido, e a distribuição espacial de fitofisionomias da Caatinga mapeadas pelo sensor MSI/Sentinel-2 e pelos dados LiDAR.

### **1.2. Objetivos**

O objetivo geral é testar o potencial uso de dados multi-temporais do sensor MSI/Sentinel-2, obtidos em quatro datas de 2015 a 2016 (período chuvoso e seco), juntamente com observações LiDAR, para o mapeamento de fitofisionomias da Caatinga, verificando a possível existência de relações entre a distribuição espacial das fitofisionomias com os atributos físico-químicos dos solos. A área de estudo é o campo experimental da Embrapa Semiárido e arredores.

De forma mais específica, pretende-se:

- a) Utilizar um mapa de referência da vegetação e observações por perfilhamento Laser (LiDAR) para descrever as diferenças na estrutura da vegetação da área de estudo;



- b) Analisar o comportamento espectro-temporal da Caatinga face ao regime de precipitação pluviométrica, usando dez bandas espectrais e seis índices de vegetação calculados a partir dos dados do sensor MSI/Sentinel-2 de quatro datas (2015 a 2016) entre as estações seca e chuvosa;
- c) Verificar eventuais ganhos de classificação decorrentes do uso de dados multi-temporais do MSI/Sentinel-2, em relação aos dados mono-temporais do período chuvoso ou seco; da adição de índices de vegetação e de métricas LiDAR no processo de classificação *Random Forest*, ranqueando o desempenho das melhores métricas;
- d) Utilizar Análise por Componentes Principais (ACP) para entender as relações de covariância de 20 atributos físico-químicos dos solos obtidos de 75 perfis, detectando e espacializando por krigagem aqueles responsáveis pela maior parte da variância dos dados;
- e) Analisar as relações entre a distribuição espacial das fitofisionomias mapeadas por *Random Forest* e a variabilidade espacial dos atributos físico-químicos mais importantes, detectados pela ACP, por meio da análise estatística de Mann-Whitney-Wilcoxon.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1. Estudos de sensoriamento remoto no ecossistema da Caatinga

A vegetação da Caatinga faz parte de um dos maiores ecossistemas brasileiros, ocupando uma área de mais de 800.000 km<sup>2</sup>, e está localizada na porção nordeste do Brasil (MORO et al., 2014). É adaptada ao clima semiárido (precipitação anual menor que 800 mm), tendo seu ciclo fenológico regulado pela oferta de água oriunda principalmente da precipitação (BARBOSA et al., 2006).

Neste ambiente, os processos de antropização da cobertura vegetal original têm motivado a maioria dos trabalhos em sensoriamento remoto. Nos últimos dez anos, por exemplo, a maioria das publicações tem abordado as mudanças de uso e cobertura do solo utilizando, majoritariamente, dados dos sensores *Thematic Mapper*, a bordo do satélite Landsat-5 (TM/Landsat-5), e *Enhanced Thematic Mapper Plus*, a bordo do satélite Landsat-7 (ETM+/Landsat-7) (SILVA A. P. N. DA et al., 2009; MELO et al., 2011; CUNHA et al., 2012; SILVA et al., 2013; COELHO et al., 2014; BEUCHLE et al., 2015; BALLÉN et al., 2016; OLIVEIRA et al., 2017). Uns poucos trabalhos utilizaram dados do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS), a bordo do satélite Terra, para estudo da Caatinga (ABADE et al., 2015; SCHULZ et al., 2017).

Outro processo de degradação, a salinização, ocasionada principalmente pela irrigação sem o manejo adequado ou em áreas sem potencial agrícola adequado, tem instigado a pesquisas como as de Moreira et al. (2015) e Rocha Neto et al. (2017). Estes autores utilizaram o sensoriamento remoto hiperespectral e multiespectral para estimar a condutividade elétrica e o caráter salino dos solos em um perímetro irrigado do Ceará. Bouaziz et al. (2011), por sua vez, utilizaram uma série de índices derivados do sensor MODIS/Terra, além de amostras de campo, para detectar solos afetados por sais no semiárido brasileiro, obtendo moderadas correlações entre a condutividade elétrica e alguns índices espectrais. Por outro lado, o trabalho de Pessoa et al. (2016) correlacionou os atributos físico-químicos de amostras de solos com dados de

sensoriamento proximal (em laboratório), a fim de estudar a influência da salinidade nos espectros de reflectância.

A desertificação também aparece como um importante foco de pesquisa que tem suscitado trabalhos na Caatinga. Foram realizados mapeamentos de áreas de desertificação na porção sul do Estado do Ceará (SÁ et al., 2014) e na região do desenvolvimento do Sertão do São Francisco (SÁ et al., 2015), correlacionando riscos associados aos tipos de vegetação, mapeados por meio dos sensores da série Landsat, com as classes de solo. Para a região do Seridó (entre o Rio Grande do Norte e a Paraíba), Petta et al. (2013) utilizaram dados dos sensores MODIS/Terra e ETM+/Landsat-7 para avaliar o processo de desertificação que ocorre nessa área, enquanto Vieira et al. (2015) identificaram grandes áreas suscetíveis a desertificação em todo o nordeste.

Outros trabalhos objetivaram a estimativa ou a validação de diversos parâmetros ou variáveis como Índice de Área Foliar (IAF) (GALVÍNCIO et al., 2013), fitomassa (COSTA et al., 2002), área basal, altura e volume da vegetação (ALMEIDA et al., 2014), biomassa lenhosa (LIMA JUNIOR et al., 2014), umidade do solo (LOPES et al., 2011), albedo (SILVA et al., 2005b; 2016), radiação solar incidente e radiação atmosférica (SILVA, et al., 2005a). Estudos de recarga de aquíferos aluviais (COELHO et al., 2017), evapotranspiração (MOREIRA et al., 2010; SILVA, et al., 2012), temperatura de superfície (BEZERRA et al., 2014) e de modelagem de fluxos de energia (TEIXEIRA et al., 2015), com base em dados de sensoriamento remoto, foram motivados, em sua maioria, pela falta de dados de campo, sendo considerados uma linha importante de pesquisa na região.

### **2.1.1. Vegetação**

As interações entre a vegetação e a radiação eletromagnética são reguladas por diversos fatores, como seus atributos biofísicos e bioquímicos, destacando-se o IAF, a quantidade de biomassa verde e senescente, a umidade, os pigmentos e o arranjo espacial de suas estruturas (THENKABAIL et al., 2012). Do ponto de vista do sensoriamento remoto, além das questões fisiológicas, a geometria de

iluminação e de visada também exercem influência no valor da reflectância medida pelo sensor (PONZONI; SHIMABUKURO, 2009).

No ambiente semiárido, as plantas desenvolveram mecanismos para sobreviver, em virtude do elevado déficit hídrico (baixa precipitação e elevada evapotranspiração) na maior parte do ano e da grande variabilidade temporal e espacial das chuvas, concentradas em 3 a 4 meses (ARAÚJO FILHO et al., 2000). Exemplos desses mecanismos são: precoce lignificação, intensa ramificação, desenvolvimento de órgãos acumuladores de água, caducifolia, presença de herbáceas anuais, suculência, acúleos e espinhos, predominância de arbustos e árvores de pequeno porte e cobertura descontínua de copas (GIULIETTI et al., 2004; SÁ; SILVA, 2010).

Além dos mecanismos individuais de sobrevivência, as plantas se associam em torno das chamadas “plantas enfermeiras” a fim de reduzir a severidade do ambiente em função do provimento de sombra, nutriente ou proteção contra o ataque de animais herbívoros (CARRIÓN et al., 2017). Estas características climatobotânicas repercutem na pronunciada sazonalidade (MORO et al., 2014, 2015) e, conseqüentemente, nos espectros de reflectância da vegetação ao longo do tempo. Além do ciclo anual, outros processos periódicos ocorrem neste bioma. No estudo feito por Barbosa et al. (2006), por exemplo, ao estudarem a variabilidade do NDVI (*Normalized Difference Vegetation Index*) para a região Nordeste do Brasil, observou-se, além do ciclo anual de oscilação, tendência consistente de aumento e de diminuição do verdejamento médio da vegetação em períodos de 7 a 8 anos. Esta característica aumenta ainda mais a complexidade dos estudos, principalmente em análises multi-temporais entre datas mais distantes. Entender a dinâmica fenológica dos diferentes tipos de fitofisionomias frente à variação da precipitação é uma difícil tarefa que ainda não foi completamente solucionada, contando com poucos estudos na Caatinga, quando comparado a outros biomas como o Cerrado e a Amazônia (BARBOSA et al., 2006).

### **2.1.2. Solos**

Na região semiárida, poucos foram os trabalhos que utilizaram dados e técnicas de sensoriamento remoto para auxiliar no mapeamento de solos. Em sua grande maioria, houve utilização de imagens de sensores orbitais ópticos e de radar apenas para a interpretação visual (ARAÚJO FILHO et al., 2000; 2012; BRAGA et al., 2009; COELHO et al., 2013).

Entretanto, alguns trabalhos se dedicaram a mensurar especificamente determinados atributos do solo, como o estudo de Rocha Neto et al. (2017) que, mapeando áreas salinizadas, estimaram valores de condutividade elétrica do solo por meio do sensoriamento remoto hiperespectral. Lopes et al. (2011), por sua vez, quantificaram e espacializaram a umidade do solo utilizando o NDVI e a temperatura de superfície, calculados a partir dos dados do sensor TM/Landsat-5. Motta et al. (1997) determinaram o tipo do solo em áreas de solo exposto utilizando dados do sensor TM/Landsat-5 com o suporte de mapas da rede de drenagem.

### **2.1.3. Interação vegetação-solo**

O solo é, no ambiente semiárido, a base das unidades de paisagens, uma vez que gerencia o recurso hídrico às plantas (SÁ; SILVA, 2010). Este ambiente, de forte interdependência entre o solo, a planta e a precipitação, é potencialmente mais afetado pelos efeitos das mudanças globais, uma vez que a pluviosidade da região é extremamente dependente dos processos oceânicos (BARBOSA et al., 2006). Além disso, os processos de desertificação na região semiárida estão intimamente ligados à degradação do solo e da vegetação (GALINDO et al., 2008), onde um ente deixa de oferecer suporte ao outro, alimentando um espiral de degradação ambiental.

Diversos autores estabeleceram, por meio de atividades de campo, as relações entre fitofisionomias da Caatinga e os solos. Numerosos trabalhos de mapeamento de solos no semiárido reportaram, ainda que de maneira empírica,

a relação solo-vegetação auxiliando, em muitos casos, na delimitação de unidades de mapeamento (JACOMINE et al., 1971; 1972; 1975; 1976; 1977; 1979; 1986; JACOMINE et al., 1973a; JACOMINE et al., 1973b; BURGOS; CAVALCANTI, 1990; ARAÚJO FILHO et al., 2000; 2012).

Na área experimental da Embrapa Semiárido, embora Burgos e Cavalcanti, (1990) não mencionem explicitamente a existência da associação solo-vegetação, eles apontaram diversos casos onde elas aparentemente ocorrem, como a presença do jericó (*Selaginella convoluta* Spring) e do caroá (*Neoglaziovia variegata*) em solos sem pedregosidade superficial, e de vegetação mais aberta nas áreas de ocorrência dos Vertissolos.

Paradella e Vitorello (1995), em um estudo geobotânico, destacaram uma série de relações entre os solos e os tipos de vegetação na região de Curaçá (BA). Foram demonstradas, por exemplo, associações entre fisionomias de Caatinga de baixa densidade (10 a 30% de cobertura), com arbustos decíduos (com altura entre 2 a 4m), com a predominância da catingueira (*Caesalpinia pyramidalis* Tull.) e do pereiro (*Aspidosperma pyriforme* Mart.) em Luvisolos cobertos com seixos de quartzo arredondado (PARADELLA; VITORELLO, 1995). Ainda no mesmo trabalho, foram encontradas associações entre Planossolos e uma densa vegetação (cobertura variando entre 60 a 80%), e entre Latossolos e uma vegetação arbustiva de cambarás (*Lantana camara* L.) e marmeleiros (*Croton* sp.) de alta densidade (cobertura maior que 80%).

Outros trabalhos usando sensoriamento remoto que associaram vegetação e solos foram focados na dinâmica do processo de desertificação (SÁ et al., 2014; 2015) e salinização. Nestes trabalhos, a degradação do solo/vegetação acarreta mudanças nos espectros de reflectância da vegetação ao longo do tempo (PETTA et al., 2013), resultando na exposição permanente do solo, que pode ser diretamente observado pelo sensor (ROCHA NETO et al., 2017).

Galindo et al. (2008) também utilizaram a relação solo-vegetação para estudar os processos de desertificação, com coletas de estratos vegetais e amostras de

campo. Estes autores observaram a redução da densidade da vegetação em função da degradação do solo (ocorrência de encrostamento superficial e teores elevados de sódio trocável).

Já nos estudos de botânica, vários trabalhos relacionam os solos e as fisionomias da Caatinga a nível de observação de campo. O primeiro trabalho que objetivou uma classificação dos tipos de fitofisionomias mais gerais de Caatinga foi o produzido por Andrade-Lima (1981), que reconheceu a forte relação entre a vegetação natural do semiárido e a diversidade de solo e clima. Embora Andrade-Lima (1981) não tenha espacializado seus resultados, a correspondência de suas observações com os levantamentos pedológicos fez com que Sampaio e Rodal (2000) propusessem esta possibilidade a partir das unidades geoambientais, definidas pelo Zoneamento Agroecológico do Nordeste (SILVA et al., 1993).

Em outros trabalhos de botânica, realizados na porção central do Estado de Pernambuco, estudos da fenologia de plantas no semiárido encontraram variações na taxa de queda de folhas e de brotação durante as mudanças sazonais, mostrando a existência de espécies mais dependentes da água disponível no solo do que outras (RODAL et al., 2008; LIMA; RODAL, 2010). Esta característica corrobora o que foi encontrado por Paradella e Vitorello, (1995) que, ao compararem em seu trabalho imagens da época seca e da época chuvosa, notaram diferenças na taxa de verdejamento entre os tipos de fisionomias.

Além de características fenológicas, o volume de solo explorado pelas raízes pode ser um parâmetro importante. Solos rasos, com horizontes de impedimentos ou com elevada pedregosidade, diminuem a massa de solo disponível para as plantas (AMARAL, 2011). Considerando a profundidade explorada pelas raízes, Pinheiro et al. (2013) dividiram suas amostras em diversas associações de solo-vegetação. Considerando apenas os solos profundos e sem qualquer camada de impedimento, os autores encontraram

valores sempre superiores e, estatisticamente significantes, de profundidade de raiz nos Argissolos em relação aos Luvisolos.

Outros estudos observaram forte influência das características do solo ao estudarem as variações fitofisionômicas ao longo de um gradiente altimétrico (FERRAZ et al., 2003) e ao mapearem a fitomassa na região do Seridó (COSTA et al., 2002). Farias et al. (2016) por sua vez, ao analisarem duas áreas próximas de Caatinga, uma mais densa e outra mais aberta, notaram diferenças estatísticas nos teores de  $Al^{3+}$  e de pedregosidade do solo, com alterações igualmente significativas nos valores de indivíduos por hectare e de área basal dos indivíduos.

## **2.2. Light Detection And Ranging (LiDAR)**

Caracterizar a estrutura do dossel vegetal é um dos maiores desafios do sensoriamento remoto. As abordagens comumente utilizadas são extremamente dependentes do comprimento de onda e da resolução espacial empregados (HARDING et al., 2001). Nos sensores passivos ópticos, a reflectância do dossel é dependente de inúmeros fatores como a estrutura da vegetação, os constituintes das folhas, a geometria de iluminação e visada, a arquitetura do dossel, a transmitância da atmosfera e a composição do solo (HARDING et al., 2001; PONZONI; SHIMABUKURO, 2009).

Instrumentos baseados na tecnologia LiDAR (*Light Detection And Ranging*) têm criado uma nova forma de sensoriamento remoto. A tecnologia LiDAR se baseia na emissão de um pulso de laser em direção ao alvo, calculando-se o tempo que este pulso leva para atingir o alvo e retornar ao sensor. Assim, a distância sensor-alvo pode ser determinada (DUBAYAH et al., 2000; LEFSKY et al., 2002; GOETZ et al., 2007).

Esta característica tornou o LiDAR conhecido como “laser altimétrico”, que tem sido utilizado em uma variedade de aplicações desde a década de 1960, quando, acoplado a uma plataforma aeromóvel, permitindo a elaboração de mapas



topográficos regionais (DUBAYAH et al., 2000). Outra característica dos sistemas LiDAR reside no fato que, de acordo com a potência do pulso laser, este pode produzir múltiplas reflexões, o que gera diversos retornos úteis dos alvos atingidos, sendo fracionado em diversos pontos refletidos (D'OLIVEIRA et al., 2014). Esta última característica, para além de uma ferramenta de topografia, fez do LiDAR um meio para se medir diretamente a distribuição tridimensional do dossel e estimar, acuradamente, atributos da estrutura da vegetação (DUBAYAH et al., 2000; LEFSKY et al., 2002).

Na última década, diversos trabalhos têm sido publicados utilizando LiDAR como ferramenta, correlacionando seus dados com diversas características da vegetação como, por exemplo, a biomassa aérea (GRATANI et al., 2013; ANDERSON et al., 2018) e o índice de área foliar de culturas agrícolas (HMIDA et al., 2017). Outra aplicação que tem obtido destaque é a caracterização do porte da vegetação a fim descrever e determinar o habitat de animais (GOETZ et al., 2007; GARCIA-FECED et al., 2011).

No Estado de Pernambuco, após a destruição de cidades inteiras com as cheias ocorridas na porção sul da região litorânea entre os anos de 2010 e 2011, o governo estadual encomendou o mapeamento das áreas afetadas e das calhas dos principais rios das bacias atingidas, realizada por meio da varredura a laser (SECRETARIA DE DESENVOLVIMENTO ECONÔMICO, 2016). A rapidez e o detalhamento do mapeamento, além da necessidade de se gerenciar os recursos hídricos, levaram a Secretaria de Recursos Hídricos e Energéticos (SRHE) a realizar o mapeamento de todo o Estado de Pernambuco, no programa que ficou conhecido como Pernambuco Tridimensional (PE3D).

Segundo Secretaria de Desenvolvimento Econômico (2016), o projeto compreende o recobrimento aerofotogramétrico e perfilhamento a laser de todo o território pernambucano, perfazendo cerca de 75 bilhões de pontos amostrados. Embora tenha sido concebido para fins de mapeamento topográfico, os modelos digitais do terreno (MDT) e os modelos digitais de

elevação (MDE) permitem a mensuração de diversos parâmetros da vegetação, como altura e distribuição espacial, tal como preconizado por autores como Dubayah et al. (2000) e Lefsky et al. (2002).

No LiDAR aerotransportado, o MDE (Modelo Digital do Elevação) corresponde à altitude da superfície exposta ao laser, ou seja, é a altitude do topo de todos os alvos presentes na cena, como construções e as copas das árvores, por exemplo. É construído a partir do primeiro retorno recebido pelo sensor e, portanto, mais próximo da aeronave. Por outro lado, o MDT (Modelo Digital do Terreno) é obtido a partir da interpolação dos últimos retornos e pela seleção de pontos em áreas onde o solo está exposto, como estradas e clareiras. O MDT corresponde, portanto, a altitude no nível do solo.

### **2.3. Sensor MSI/Sentinel-2**

O Programa *Global Monitoring for Environment and Security* (GMES) é uma iniciativa conjunta da União Europeia (UE) e da Agência Espacial Europeia (ESA - *European Space Agency*). Seu objetivo é prover dados precisos e acessíveis de satélite, rapidamente, a fim de melhorar o gerenciamento ambiental; e entender e mitigar os efeitos das mudanças climáticas, além de garantir a segurança civil (ASCHBACHER et al., 2010). É considerado, até a presente data, o mais ambicioso programa de observação da Terra (ASCHBACHER; MILAGRO-PÉREZ, 2012).

O programa GMES é composto por três componentes, sendo o primeiro *in situ*, que inclui observações e coletas de dados locais por meio de instrumentos e aparelhos instalados em plataformas aéreas, marítimas e terrestres. O segundo componente é de serviço, que está incumbido da geração e da disponibilização dos dados e de informações para a implementação de políticas públicas, como monitoramento da terra, do mar e da atmosfera, gestão de emergências, e as seguranças pública e nacional. Finalmente, o último componente é o espacial, que inclui cerca de 40 missões de satélites (ASCHBACHER; MILAGRO-PÉREZ, 2012).

No componente espacial, destacam-se as missões Sentinel, divididas em 5 famílias de satélites: a missão Sentinel-1, equipada com radar imageador na banda C; a missão Sentinel-2, aparelhado com um imageador multiespectral; a missão Sentinel-3, que será dotada de diferentes instrumentos para medir diversos parâmetros da terra e do mar; e as missões Sentinel-4 e Sentinel-5, voltadas para a aquisição de dados da composição atmosférica (ASCHBACHER et al., 2010).

A missão Sentinel-2 é constituída de 2 satélites (A e B), com órbita sol-síncrona e altitude média de 800 km e que, juntos, têm a capacidade de revisita de 5 dias no equador, e de 2 a 3 dias nas latitudes médias (EUROPEAN SPACE AGENCY, 2012). Igualmente, a fim de obter uma menor cobertura de nuvens, uma boa iluminação solar e uma similaridade com os dados da série Landsat e SPOT, os satélites da missão Sentinel-2 cruzam o equador às 10:30 a.m. do horário local (DRUSCH et al., 2012).

Ambos os satélites da missão Sentinel-2 (2A e 2B) contam com o sensor *MultiSpectral Instrument* (MSI) com 13 bandas espectrais, de elevada qualidade geométrica e radiométrica, voltadas para o monitoramento terrestre (DRUSCH et al., 2012), cujas características são mostradas na Tabela 2.1 e na Tabela 2.2.

Tabela 2.1 - Características espectrais e espaciais do sensor MSI/Sentinel-2A.

Banda	Centro da banda nm	Largura nm	Resolução m	Relação sinal ruído - Lref
1	443,9	27	60	129
2	496,6	98	10	154
3	560,0	45	10	168
4	664,5	38	10	142
5	703,9	19	20	117
6	740,2	18	20	89
7	782,5	28	20	105
8A	864,8	33	20	174
8	835,1	145	10	72
9	945,0	26	60	114
10	1373,5	75	60	50
11	1613,7	143	20	100
12	2202,4	242	20	100

Fonte: European Space Agency (2018).

Tabela 2.2 - Características espectrais e espaciais do sensor MSI/Sentinel-2B.

Banda	Centro da banda nm	Largura nm	Resolução m	Relação sinal ruído - Lref
1	442,3	45	60	129
2	492,1	98	10	154
3	559,0	46	10	168
4	665,0	39	10	142
5	703,8	20	20	117
6	739,1	18	20	89
7	779,7	28	20	105
8A	864	32	20	174
8	833,0	133	10	72
9	943,2	27	60	114
10	1376,9	76	60	50
11	1610,4	141	20	100
12	2185,7	238	20	100

Fonte: European Space Agency (2018).

As bandas do Sentinel-2 cobrem as regiões espectrais do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). As quatro bandas com resolução espacial de 10 metros (2, 3, 4 e 8), foram definidas para manter a compatibilidade com os produtos SPOT, enquanto que as bandas de 20 metros de resolução espacial, foram concebidas para observar principalmente as características da vegetação (borda vermelha da vegetação e a banda de absorção da lignina) (EUROPEAN SPACE AGENCY, 2012). As bandas de resolução espacial de 60 metros são destinadas a correção atmosférica (EUROPEAN SPACE AGENCY, 2012).

Antes mesmo do lançamento do primeiro satélite Sentinel-2, diversos autores testaram suas características no mapeamento de propriedades químicas e físicas da vegetação utilizando, para isto, dados de sensores hiperespectrais como o CASI (*Compact Airborne Spectrographic Imager*) (DELEGIDO et al., 2011), CHRIS/PROBA (*Compact High Resolution Imaging Spectrometer*) (DELEGIDO et al., 2013) e o HyMap (DELEGIDO et al., 2015). Foram também utilizados espectrômetros não-imageadores como o FieldSpec (RAMOELO et al., 2015; SIBANDA et al., 2015) e o HR-786 (DONG et al., 2015).

Nestes estudos e em outros trabalhos que simularam dados do Sentinel-2, foi encontrada boa correlação com a reflectância ao se estimar diversos atributos biofísicos e bioquímicos, como a clorofila e o IAF (DELEGIDO et al., 2011; FRAMPTON et al., 2013); a radiação fotossinteticamente ativa (DONG et al., 2015); a concentração de nitrogênio nas folhas (RAMOELO et al., 2015); a biomassa acima do solo (SIBANDA et al., 2015); e o IAF verde e senescente (DELEGIDO et al., 2015).

Os dados do sensor MSI/Sentinel-2 são disponibilizados ao público como reflectância no topo da atmosfera e são orto-corrigidos (nível 1C), sendo possível a correção para a reflectância de superfície (nível 2A) por meio do algoritmo *Sentinel-2 Atmospheric Correction* (Sen2Cor). Este algoritmo utiliza as bandas de aerossol (443 nm), de absorção de vapor d'água atmosférico (945 nm) e de nuvens cirros (1375 nm) em funções de transferência radiativa, oriundas de *look-up tables* (LUT) e geradas a partir da biblioteca LibRadtran, que calculam a radiação solar e termal na atmosfera terrestre (MUELLER-WILM et al., 2015; EMDE et al., 2016; LOUIS et al., 2016).

#### **2.4. Índices de vegetação (IVs)**

O primeiro índice de vegetação, proposto por Jordan (1969), baseia-se em uma razão entre os valores de reflectância das regiões do vermelho e do infravermelho próximo, correlacionando-os com o IAF. O comportamento antagônico da vegetação nestas duas regiões do espectro eletromagnético está associado à forte absorção pelos pigmentos foliares e ao espalhamento múltiplo da radiação nas diferentes camadas de folhas (PONZONI; SHIMABUKURO, 2009; FORMAGGIO; SANCHES, 2017). Índices foram então desenvolvidos a partir desta relação, com Rouse et al. (1973) propondo a normalização da razão simples no chamado *Normalized Difference Vegetation Index* (NDVI), que se tornou subsequentemente o índice de vegetação mais conhecido e aplicado.

Experimentos ao longo de todos os anos 70 e início dos anos 80 ajudaram a entender melhor as relações entre a reflectância da vegetação os processos

bioquímicos e fenológicos. Apesar de ter sido proposto primeiramente por Kimes et al. (1981), foi Hardisky et al. (1983) que mostraram o potencial da relação entre o infravermelho próximo e o infravermelho de ondas curtas para a predição do conteúdo de água nas folhas. Este índice foi denominado por estes autores como *Normalized Difference Infrared Index* (NDII).

Já em meados dos anos 1980, as limitações do NDVI (e.g. influência do solo e da atmosfera) eram evidentes, o que deu início a pesquisas que objetivavam corrigir ou minimizar os problemas documentados. Outros índices foram desenvolvidos, como o OSAVI (*Optimized Soil-Adjusted Vegetation Index*), o ARVI (*Atmospherically Resistant Vegetation Index*) e o EVI (*Enhanced Vegetation Index*), apresentados, respectivamente, por Rondeaux (1996), Kaufman e Tanré (1992) e Huete et al (1997).

O EVI utiliza fatores de ajustes e a reflectância no azul para corrigir a influência indesejada da atmosfera e do solo, este último mais acentuado no ambiente semiárido (HUETE et al., 1997; HUETE; JUSTICE, 1999). Nestas condições climáticas, diferentes autores têm encontrado uma boa relação entre EVI e métricas biofísicas da vegetação como o IAF (ALMEIDA, 2016; CARVALHO et al., 2017), a biomassa (JAVZANDULAM et al., 2005; CHAVES et al., 2013) e a produção primária líquida (CABELLO et al., 2012).

Da mesma forma, o OSAVI, proposto por Rondeaux e al. (1996), tem por objetivo reduzir a influência do solo na reflectância medida da vegetação. Buscando estimar a clorofila a partir de índices de vegetação hiperespectrais, Wu et al. (2008) adaptaram a fórmula do OSAVI no produto TCARI/OSAVI e MCARI/OSAVI para utilização da borda vermelha, por meio das bandas de 705 nm e 750 nm, com resultados muito bons na predição do teor de clorofila em folhas de milho.

Frente a estes resultados, Clevers e Gitelson (2013), utilizando um experimento com grama e milho, compararam a capacidade das bandas de 705 nm e 740 nm do Sentinel-2 de prognosticar teores de clorofila e nitrogênio no dossel,

concluindo que as bandas citadas têm um bom potencial. Paralelamente, Dong et al. (2015), visando determinar a radiação fotossinteticamente ativa absorvida por culturas agrícolas, utilizaram o OSAVI com as bandas de 5 e 6 do Sentinel-2, encontrando um coeficiente de determinação muito superior ao do OSAVI originalmente proposto por Rondeaux et al. (1996).

## **2.5. Classificador Random Forest (RF)**

O desenvolvimento da informática tem permitido significativos avanços nas técnicas de classificação de imagens. Além das bem conhecidas abordagens estatísticas, alguns dos métodos mais recentes, baseados no campo do aprendizado de máquinas (*machine learning*), têm sido empregados com grande sucesso no sensoriamento remoto (WASKE et al., 2009). O aprendizado de máquinas pode ser definido como um processo automático de revelação de padrões, utilizando modelos estatísticos baseados em computador sobre grandes bancos de dados e que, fundado num modelo ajustado a partir dos padrões revelados, pode então ser usado para propósitos de predição em novos dados (HEUNG et al., 2016). As técnicas de aprendizado de máquina são, portanto, classificadores supervisionados e não paramétricos que podem superar algumas dificuldades dos modelos de mistura espectral (CLARK; KILHAM, 2016).

O algoritmo *Random Forest* (RF) é um dos diversos algoritmos de aprendizado de máquinas que foi introduzido no sensoriamento remoto nos últimos anos (LARY et al., 2016). É baseado na combinação de árvores de decisão de modo que cada árvore dependa dos valores de um vetor randômico, amostrado independentemente e com a mesma distribuição de todas as árvores na floresta (BREIMAN, 2001). Desta forma, o RF constrói cada árvore usando um algoritmo determinístico, que seleciona um conjunto casual de variáveis com uma amostra aleatória a partir dos dados de calibração (RAMOELO et al., 2015). Depois que um grande número de árvores é gerado, cada uma delas classifica o pixel em análise em uma determinada classe. O somatório das diversas classificações

determinará a classe final a qual aquele pixel pertence (BREIMAN, 2001; LARY et al., 2016).

O RF possui dois parâmetros básicos que precisam ser bem definidos: o número de árvores na floresta e o número de nós em cada árvore (RODRIGUEZ-GALIANO et al., 2012; RAMOELO et al., 2015). Embora seja considerado um modelo complexo, sua parametrização não exige maior demanda de tempo quando comparado a outros modelos complexos, como redes neurais e *Support Vector Machine* (SVM) (HEUNG et al., 2016).

RF tem sido usado em mapeamentos de vegetação por meio do sensoriamento remoto, apresentando bons resultados, uma vez que consegue acomodar diferentes respostas espectro-temporais, boa velocidade de classificação e de treinamento, com poucos parâmetros definidos pelo usuário (CLARK; KILHAM, 2016). RF possui ainda desempenho melhor, ao mesmo tempo em que supera algumas deficiências de encapsulamento e impulso existentes em outras abordagens de aprendizado de máquina (WASKE et al., 2009).

## **2.6. Análise por Componentes Principais (ACP)**

Os objetivos principais da análise por componentes principais (ACP) (em inglês *Principal Component Analysis* -PCA), são o de explicar a estrutura da variância e da covariância dos dados e a redução da dimensionalidade dos dados (HÄRDLE; SIMAR, 2003; JOHNSON; WICHERN, 2007). ACP é uma técnica de estatística multivariada que, por meio da transformação linear de um grupo de variáveis correlacionadas, permite que certas condições ideais sejam alcançadas (JACKSON, 2004). Estas transformações algébricas lineares resultam em combinações, chamadas de componentes principais (CP), e que não são correlacionadas entre si, onde  $p$ -variáveis resultam em  $p$ -componentes (MINGOTI, 2005). Geometricamente as combinações lineares resultam na rotação do sistema cartesiano original para um novo, onde seus eixos representam a direção da máxima variabilidade (JOHNSON; WICHERN, 2007).



A obtenção dos coeficientes das componentes principais necessita da criação de uma matriz de covariâncias teórica ( $\Sigma_{p \times p}$ ) ou de correlação teórica ( $P_{p \times p}$ ) alcançadas, respectivamente, por meio das matrizes de covariâncias amostral ( $S_{p \times p}$ ) ou de correlação amostral ( $R_{p \times p}$ ) (JOHNSON; WICHERN, 2007). Apesar de compatíveis, os resultados obtidos para os coeficientes das componentes principais por meio de uma ou outra matriz não são iguais. Para componentes principais obtidas por meio da matriz de covariância, há a necessidade de um número menor de componentes para se explicar a mesma quantidade de variância (MINGOTI, 2005). Por outro lado, as matrizes de covariância são fortemente influenciadas pelas variáveis de maior variância, tornando-a de pouca utilidade em casos onde, ou há variáveis com diferentes unidades de medidas, ou em casos onde suas variâncias são demasiado diferentes (JACKSON, 2004).

A matriz de correlação teórica ( $R_{p \times p}$ ) dos vetores aleatórios de interesse, onde o coeficiente de correlação amostral ( $R_{ij}$ ) entre as *i*-ésimas e *j*-ésimas variáveis é obtido por meio do coeficiente de correlação de Pearson, conforme

$$R_{p \times p} = \begin{bmatrix} R_{11} & \cdots & R_{1p} \\ \vdots & \ddots & \vdots \\ R_{p1} & \cdots & R_{pp} \end{bmatrix}$$

A matriz  $R_{p \times p}$  é então subtraída por uma matriz imagem

$$I_{p \times p} = \begin{bmatrix} \lambda_{11} & \cdots & 0_{1p} \\ \vdots & \ddots & \vdots \\ 0_{p1} & \cdots & \lambda_{pp} \end{bmatrix}$$

, gerando um polinômio de grau igual a  $p$ , cuja raiz  $\lambda$  são os autovalores da matriz de correlação (MINGOTI, 2005). Finalmente, realiza-se o cálculo do autovetor  $\alpha$

$$\alpha = \begin{bmatrix} \alpha_{11} \\ \alpha_{12} \\ \alpha_{13} \end{bmatrix}$$

de modo que  $R_{p \times p} \alpha = \lambda \alpha$ , para todos os autovalores.

A fim de se avaliar a qualidade da ACP, dois testes são bastante utilizados na literatura. O primeiro teste nasceu da necessidade de se validar a aplicação de

um modelo, baseado na análise fatorial, sobre uma matriz de correlação (CERNY; KAISER, 1977). Kaiser (1970) propôs o que ele chamou de *Measure of Sampling Adequacy* (MSA) ou, como ficou conhecido posteriormente, medida de Kaiser-Meyer-Olkin (KMO). A KMO baseia-se no princípio de que a matriz de correlação inversa ( $R_{p \times p}^{-1}$ ) seja próxima à matriz diagonal para que um modelo de análise fatorial esteja corretamente ajustado aos dados, verificando se as correlações parciais entre as variáveis são próximas a zero (MINGOTI, 2005). Desta forma, a KMO retorna um valor entre 0 e 1, onde maiores valores indicam uma melhor adequabilidade da análise fatorial e, conseqüentemente, correlações parciais mais baixas (CERNY; KAISER, 1977; IBM, 2013). Segundo Kaiser e Rice (1974), os valores da KMO abaixo de 0,5 são considerados inaceitáveis e os valores acima de 0,8 apresentam uma boa adequação do modelo.

O segundo teste, chamado de esfericidade de Bartlett, testa a hipótese de que a variância da matriz de correlação populacional é igual a variância da matriz identidade ( $H_0: P_{p \times p} = ID_{p \times p}$ ) medindo a distância T, onde o ajuste do modelo só pode ser feito a partir da rejeição da hipótese (BARTLETT, 1950; JOHNSON; WICHERN, 2007). A rejeição da hipótese se dá quando o valor medido T é maior ou igual ao valor crítico da distribuição qui-quadrado de acordo com o nível de significância escolhido para o teste, uma vez que, sob hipótese nula e  $n$  grande, a estatística T tem distribuição aproximada à uma qui-quadrado com  $1/2p(p-1)$  graus de liberdade (MINGOTI, 2005).

Pela semelhança da análise fatorial com a ACP, a medida de Kaiser-Meyer-Olkin e a esfericidade de Bartlett foram incorporadas com sucesso por inúmeros autores que trabalharam análise por componentes principais como Moura et al. (2017) e Corner et al. (2013).

## **2.7. Krigagem**

Os diversos atributos dos solos não ocorrem de maneira aleatória na natureza, sendo resultado dos diversos processos bióticos e abióticos, como clima,

organismos vivos e relevo. Estes fatores contribuem para a transformação do material de origem no corpo tridimensional que representa o solo.

No espaço geográfico, as relações de vizinhança e proximidade descrevem o comportamento no que foi definido como dependência espacial. Desta forma, a ocorrência de grande parte dos fenômenos naturais apresenta entre si uma relação que depende da distância (DRUCK et al., 2004).

Deste modo, a geoestatística visa à caracterização espacial de uma variável de interesse, mediante o estudo de sua distribuição e variabilidade espacial, com a determinação das incertezas associadas (YAMAMOTO; LANDIM, 2013). Diversos são os modelos geoestatísticos que foram desenvolvidos desde a segunda metade do século passado, principalmente a partir dos trabalhos pioneiros de exploração mineral (MEIRELLES et al., 2007). Dentre estas técnicas, destaca-se a krigagem (ou krigeagem), desenvolvida com base nos trabalhos de Daniel Krige na África do Sul e que possui, como característica, o uso de um semivariograma para medir a variância entre pontos separados por uma dada distância (YAMAMOTO; LANDIM, 2013).

Quando comparado a outras técnicas de interpolação, como a média ponderada ou o inverso da distância, a krigagem estima um atributo com maior precisão, através de um modelo confiável e não tendencioso (MEIRELLES et al., 2007; YAMAMOTO; LANDIM, 2013). Possui também a capacidade de, em função de modelos matemáticos de transformação de dados, trabalhar com diferentes distribuições amostrais, eliminando os efeitos, por exemplo, da grande quantidade de baixos valores em assimetria positiva (YAMAMOTO; LANDIM, 2013).


Na ciência do solo, a krigagem tem se tornado bastante popular, sendo reconhecido como um interpolador eficiente. Por conta de sua característica interna de quantificar a variabilidade espacial por meio da função de covariância, é capaz de gerar mapas de previsão ótima e de erro padrão associado aos dados ruidosos ou incompletos (VISCARRA ROSSEL et al., 2011).

Na literatura observam-se diversos trabalhos onde os autores utilizaram a krigagem para interpolar atributos químicos e físicos do solo, como condutividade elétrica (NIÑEROLA et al., 2017); areia, silte e argila (MEDINA et al., 2017); teor de água do solo, porosidade, densidade do solo, resistência à penetração, retenção de água (GREGO; VIEIRA, 2005); matéria orgânica, cálcio e magnésio (VIEIRA et al., 2011); pH, potássio (CARVALHO et al., 2002); alumínio, ferro, soma e saturação por bases (GUEDES FILHO et al., 2010) e de contaminantes no solo (TAVARES et al., 2008; HA et al., 2014).

### 3 ÁREA DE ESTUDO

A área de estudo, localizada no município de Petrolina no Estado de Pernambuco (Figura 3.1), é o campo experimental da Embrapa Semiárido (conhecido anteriormente como Centro de Pesquisa Agropecuária do Trópico Semiárido - CPATSA) e arredores ao norte. A área total corresponde a 5.629 ha, sendo que 2.776 ha pertencem ao antigo CPATSA.

Figura 3.1 – Localização da área de estudo: a) mapa do Brasil com a área do semiárido; b) posição da área de estudo na região semiárida; c) composição MSI/Sentinel-2 do dia 14/05/2016, e d) composição MSI/Sentinel-2 do dia 22/08/2016. Em (c) e (d), as bandas de 842 nm(R), 665 nm (G) e 2190nm (B) foram utilizadas na composição colorida.



Fonte: Produção do autor.


O clima é BSw<sup>h</sup> na classificação de *Köppen*, com temperaturas elevadas e baixa precipitação, com estação chuvosa no verão. Na classificação de Gaussen, a área de estudo está inserida no bioclima 2b, isto é, subdesértico quente de tendência tropical, índice xerotérmico entre 200 e 300, com 9 a 11 meses secos e temperatura do mês mais frio superior a 15°C (BURGOS; CAVALCANTI, 1990).

O regime pluviométrico é o regido pelos sistemas frontais e vórtices ciclônicos de ar superior, onde a precipitação média anual é de 578 mm, frente ao total anual de evapotranspiração potencial de 1500 mm. O período chuvoso ocorre nos meses de janeiro, fevereiro e março com temperatura média em torno dos 26°C (ARAÚJO FILHO et al., 2000).

A Figura 3.2 mostra a distribuição mensal da precipitação para os anos de 2015 e 2016 (anos cujas imagens MSI estão disponíveis) na área de estudo, a partir dos dados da estação meteorológica instalada nas dependências da Embrapa Semiárido, além da divisão em quintis da série histórica. A irregularidade das chuvas, típica do semiárido nordestino, é marcante. O período chuvoso de 2015 pode ser considerado como normal em relação à série histórica (1975-2015). A estação chuvosa de 2016 foi atípica em janeiro (bastante chuvoso) e com precipitação abaixo da média nos meses seguintes (fevereiro a abril), quando comparado com a série histórica.

Na área de estudo, a vegetação predominante foi classificada, em um mapeamento na escala 1:100.000, como Caatinga densa (ACCIOLY et al., 2017). Burgos e Cavalcanti, (1990), por sua vez, descreveram especificamente a vegetação da área de estudo como Caatinga hiperxerófila, de formação caducifólia espinhosa, predominantemente arbustiva-arbórea, cujo porte mais elevado de altura é definido pelas “braúnas” (*Schinopsis brasiliensis*). Observaram, no entanto, algumas formações mais abertas, associadas às manchas de Vertissolo.

Figura 3.2 - Precipitação acumulada mensal em mm para o período de dezembro de 2015 a agosto de 2016 com o quintil mensal da precipitação baseada na série histórica de 1975 a 2015.



Fonte: Embrapa Semiárido (2017).

Diversos estudos florísticos e fitossociométricos foram desenvolvidos na área de estudo. Estes estudos destacaram a dominância da Jurema-preta (*Mimosa tenuiflora* (Willd.) Poir) e da Braúna (*Schinopsis brasiliensis* Engl.) no estrato arbóreo-arbustivo (ALBUQUERQUE; BANDEIRA, 1995; DRUMOND et al., 2000; CALIXTO JÚNIOR; DRUMOND, 2014; ALVES et al., 2017).

Calixto Junior et al. (2011), ao estudarem a estrutura e distribuição espacial da Jurema-preta em dois fragmentos na área de estudo, encontraram indivíduos de até quase sete metros, embora a maior parte dos indivíduos (80,9%) tenha altura entre 3 e 5 metros. Segundo o Índice de Payandeh, ocorrem em uma distribuição agregada.

A Tabela 3.1 mostra a síntese de quatro trabalhos que realizaram levantamentos fitossociológicos na área de estudo em questão, onde é possível observar significativas diferenças na concentração de espécies.

Tabela 3.1 – Número de indivíduos por hectare obtidos por levantamentos florísticos realizados na área de estudo, onde I, II, III e IV correspondem respectivamente aos estudos de Drumond et al. (2000), Albuquerque e Bandeira (1995), Calixto Júnior e Drumond (2011) e Alves et al. (2017).

FAMÍLIA/Espécie	Nome popular	I	II	III	IV
<b>ANACARDIACEAE</b>					
<i>Schinopsis brasiliensis</i> Engl.	Baraúna	2	6.1	3.1	35
<i>Spondias tuberosa</i> Arr.	Umbu	1	3		
<b>APOCYNACEAE</b>					
<i>Aspidosperma pyrifolium</i> Mart	Pareiro			15.7	
<b>BIGNONIACEAE</b>					
<i>Handroanthus spongiosus</i> (Rizzini) S.Grose	Sete-cascas				1510
<i>Tabebuia spongiosa</i> Rizz.	Sete-cascas	12.5	45.4	81.3	
<b>BOMBACACEAE</b>					
<i>Pseudobombax simplicifolium</i> A. Robyns	Embiruçu	1.8			
<b>BORAGINACEAE</b>					
<i>Cordia leucocephala</i>	Moleque- duro		2173.3		
<i>Varronia leucocephala</i> (Moric.) J.S.Mill.	Moleque- duro				5
<b>BURSERACEAE</b>					
<i>Commiphora leptophloeos</i> (Mart.) Gillet.	Umburana	9.7	15.1		95
<b>CACTACEAE</b>					
<i>Cereus jamacaru</i> DC	Mandacaru			3.1	
<i>Senegalia piauhiensis</i> (Benth.) Seigler & Ebinger	Facheiro				5
<b>CAESALPINACEAE</b>					
<i>Bauhinia cheilantha</i>	Mororó		1041.6	43.7	
<i>Caesalpinia ferrea</i> Mart	Pau-ferro			3.1	
<i>Caesalpinia microphylla</i> Buch.-Ham.	Catinga-de- porco				3.1
<i>Caesalpinia microphylla</i> Mart.	Catinga-de- porco		94.7		
<i>Caesalpinia multiflora</i> Mart.	Catinga-de- porco	41	60.6		
<i>Senna macranthera</i> (DC. ex Collad.) H.S. Irwin & Barneby	Fedegoso			3.1	5
<b>CARICACEAE</b>					
<i>Jacaratia corumbensis</i> Kuntze	Mamãozinh o-de-veado				15
<b>CELASTRACEAE</b>					
<i>Fraunhoferia multiflora</i> Mart.	Pau-branco	4.3			5
<b>ERYTHROPALACEAE</b>					
<i>Erythroxylum</i> sp	Pimentinha- do-mato				5

(Continua)




Tabela 3.1 - Continuação

FAMÍLIA/Espécie	Nome popular	I	II	III	IV
<b>EUPHORBIACEAE</b>					
<i>Cnidoscolus baianus</i> (Ule.) Pax et K. Hoffman	Favela-brava		75.7		35
<i>Cnidoscolus phyllacanthus</i> Pax et K. Hoffman	Favela	32.5	59.1		
<i>Cnidoscolus quercifolius</i> Pohl	Favela			46.8	5
<i>Croton conduplicatus</i> Kunth	Quebra-faca				305
<i>Croton rhamnifolius</i>	Quebra-faca		2111.7		
<i>Croton sonderianus</i> Müll.Arg.	Marmeleiro-preto				45
<i>Jatropha mollissima</i> (Pohl.) Baill.	Pinhão		203.6		45
<i>Jatropha mollissima</i> Muell. Arg.	Pinhão-bravo	5.7		25.0	
<i>Manihot pseudoglaziovii</i> Pax et k. Hoffman	Maniçaba	4.2		56.3	160
<i>Sapium laceolatum</i> (Muell. Arg.) Herber	Burra-leiteira	2.3			
<i>Sapium</i> sp 2	Burra-leiteira				20
<i>Sapium</i> sp.	Burra-leiteira				80
<b>FABACEAE</b>					
<i>Acacia paniculiflora</i> Steudel					40
<i>Bauhinia cheilantha</i> (Bong.) Steud.	Mororó				75
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	Jurema-vermelha				15
<i>Poincianella microphylla</i> (Mart. ex G.Don) L.P. Queiroz	Catingueirinha				255
<b>MIMOSACEAE</b>					
<i>Anandenthera macrocarpa</i> (Benth.) Brenan	Angico-vermelho	2		6.2	
<i>Calliandra depauperata</i>	Carqueja		454.5		
<i>Mimosa Arenosa</i> (Willd.) Poir.	Unha-de-gato			131.2	
<i>Mimosa stipulacea</i>				21.9	
<i>Mimosa tenuiflora</i>	Jurema-preta		18.9		
<i>Mimosa tenuiflora</i> (Willd.) Poir	Jurema-preta	43.5	200	884.4	295
<b>VERBENACEAE</b>					
<i>Lantana camara</i> L.	Cambará		28.4		
<i>Lippia microphylla</i>	Alecrim-de-tabuleiro		3196	21.9	

Fonte: Adaptado dos trabalhos de Drumond et al. (2000), Albuquerque e Bandeira (1995), Calixto Júnior e Drumond (2011) e Alves et al. (2017).

Com relação aos solos, Burgos e Cavalcanti, (1990) mapearam em detalhe os solos da unidade (Figura 3.3) na estação, destacando os Argissolos Vermelho-Amarelo (98,6% da área de estudo), os Planossolos Háplicos (1,1% da área) e os Vertissolos Háplicos (0,3% da área).

Figura 3.3 - Mapa de solos e localização dos 75 perfis amostrados no Campo Experimental da Embrapa Semiárido, Petrolina (PE).



Fonte: Burgos e Cavalcanti, (1990).

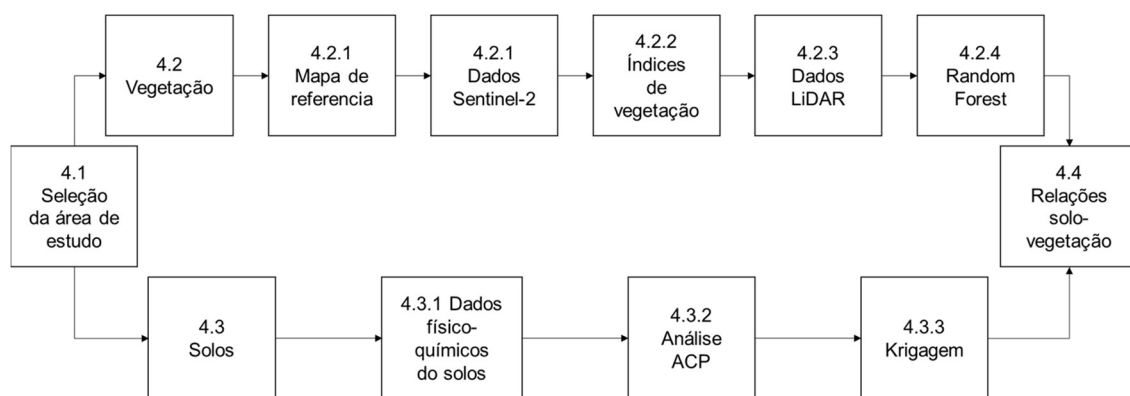
Burgos e Cavalcanti, (1990) ainda subdividiram os Argissolos presentes na área em cinco grupos:

- Argissolos profundos, que possuíam profundidade maior do que 150 cm, livres de impedimentos como pedregosidade ou duripã;
- Argissolos com fase pedregosa do tipo III.2, quando a pedregosidade encontrava-se entre 150 e 100 cm de profundidade;
- Argissolos com fase pedregosa do tipo III.1, com a fase pedregosa entre 100 e 40 cm;
- Argissolos com fase pedregosa do tipo I, quando a pedregosidade é superficial, e;
- Argissolos rasos, normalmente pedregosos, cujo substrato rochoso encontra-se a profundidade de até 50 cm da superfície.

## 4 MATERIAIS E MÉTODOS

A Figura 4.1 apresenta de maneira resumida as etapas desenvolvidas neste trabalho, que serão detalhadas ao longo desta seção.

Figura 4.1 – Fluxograma das etapas realizadas neste trabalho.



Fonte: Produção do autor.

### 4.1. Seleção da área de estudo

A área de estudo foi selecionada pela boa representação do ambiente das Caatingas hiperxerófilas do Brasil. Além disso, uma vez que parte da área de estudo está contida em um centro de pesquisa, com acesso controlado, sua vegetação encontra-se bastante preservada, exibindo feições fitofisionômicas da cobertura original. Os arredores estão mais afetados por atividades antrópicas. Outro ponto relevante é o fato de boa parte da área de estudo possuir um levantamento detalhado dos solos, produzido por Burgos e Cavalcanti, (1990), na escala 1:7.500, com um total de 75 perfis completos descritos e com análises físicas e químicas. Dados LiDAR também estão disponíveis para esta área.

### 4.2. Estudo da Vegetação

#### 4.2.1. Obtenção do mapa de referência (fotografias aéreas e atividades de campo)

Diante da inexistência de mapa da vegetação da área de estudo, fotografias aéreas digitais do Projeto PE3D, com suporte de atividades de campo, foram

utilizadas para a geração de um mapa de referência. As atividades de campo foram realizadas em setembro de 2017 com o apoio da equipe de sensoriamento remoto da vegetação da Embrapa Semiárido. Foram visitados 132 locais e obtidas mais de 800 fotografias, devidamente georreferenciadas, registrando a predominância da fitofisionomia do local.

A chave de classificação utilizada no trabalho foi a proposta por Sá (2008), durante o 59º Congresso Nacional de Botânica na cidade de Natal (RN). Diferentemente de outros esquemas de classificação, Sá (2008) propôs uma classificação puramente fisionômica, sem a inclusão de expressões florísticas (e.g., com e sem palmeiras), geográficas (e.g., de montanha ou de galeria) ou regionais (e.g., dos Cariris ou do Seridó).

A razão para a escolha deste sistema de classificação é a sua maior compatibilidade com as observações feitas por satélites sobre a densidade e estrutura da cobertura vegetal da Caatinga. Sá (2008) estabeleceu duas estratificações para a classificação das fitofisionomias: uma vertical (Tabela 4.1), baseada na altura dos indivíduos arbóreos, e outra horizontal (Tabela 4.2), baseada na densidade de cobertura do solo pela vegetação.

Tabela 4.1 - Estratificação vertical para fitofisionomias de Caatinga.

Classe	Altura (m)
Arbórea	> 5
Arbórea-arbustiva	3,5 a 5
Arbustiva	2 a 3,5
Subarbustiva	0,5 a 2
Gramíneo-lenhosa	< 0,5

Fonte: Sá (2008).

Tabela 4.2 - Estratificação horizontal para fitofisionomias de Caatinga.

Classe	Cobertura (%)
Densa	> 80
Semi-densa	50 a 80
Aberta	30 a 50
Rala	< 30

Fonte: Sá (2008).

O mapa gerado a partir da vetorização em tela do mosaico das fotografias aéreas digitais e das informações de campo foi submetido à uma avaliação pela equipe de mapeamento da vegetação da Embrapa Semiárido, que propôs modificações, validando, posteriormente seu resultado final.

#### 4.2.2. Aquisição e pré-processamento das imagens MSI/Sentinel-2A

Para o presente estudo foram adquiridas quatro imagens do sensor MSI/Sentinel-2A, no período de dezembro de 2015 a agosto de 2016 (Tabela 4.3). As imagens de dezembro de 2015 e maio de 2016 representam a transição da estação seca para chuvosa e da chuvosa para a seca, respectivamente. As duas imagens restantes (julho e agosto de 2016) foram obtidas durante o período seco. A amplitude de variação do ângulo zenital solar entre julho e dezembro foi de aproximadamente 12° (Tabela 4.3).

Tabela 4.3 - Imagens MSI/Sentinel-2 livres de nuvens disponíveis para a área de estudo, com suas respectivas geometrias de iluminação.

Data	Estação	Ângulo solar	
		Zenital	Azimutal
26/12/2015	seca/chuvosa	26,96°	123,50°
14/05/2016	chuvosa/seca	35,76°	39,73°
13/07/2016	Seca	39,41°	39,26°
22/08/2016	Seca	31,90°	51,21°

Fonte: Produção do autor.

As imagens MSI foram obtidas em reflectância no topo da atmosfera (nível 1C) e foram convertidas para reflectância de superfície (nível 2A) por meio do algoritmo “*Sentinel-2 Atmospheric Correction*” (Sen2Cor). Os seguintes parâmetros foram utilizados para fins de correção atmosférica:

- a) Aerossol com modelo Rural de verão (equatorial), uma vez que a área de estudo está localizada na parte continental dentro da faixa equatorial;

- b) Conteúdo de ozônio de 250 DU para as imagens de 22/12/2015, 14/05/2016 e 13/07/2016 e de 290 DU para a imagem de 22/08/2016. Os valores foram definidos tendo como base o ajuste ao total diário de ozônio, medido pelo sensor *Ozone Monitoring Instrument* (OMI) a bordo do satélite Aura (LEVELT; NOORDHOEK, 2002; DOBBER et al., 2006);
- c) Correção do vapor d'água usando a banda 9 do sensor MSI/Sentinel-2A posicionada em um intervalo espectral de forte absorção por vapor d'água da atmosfera (945 nm).

O algoritmo também considerou a possível presença de nuvens cirros. Considerando que a área é relativamente plana, não houve necessidade de correção topográfica usando modelos digitais de elevação, com a altitude média definida em 375 m, tomando como base o levantamento topográfico detalhado, na escala 1:5.000 (EMBRAPA, 1981).

Após correção atmosférica, foi realizado o registro das cenas do Sentinel-2 por meio das imagens de alta resolução LiDAR obtidas do projeto Pernambuco Tridimensional (SECRETARIA DE DESENVOLVIMENTO ECONÔMICO, 2016). Este corregristo objetivou a concordância entre os dois produtos de sensoriamento remoto.

#### **4.2.3. Reflectância e índices de vegetação**

Para fins de análise de dados, as bandas 1, 9 e 10 do MSI (60 metros de resolução espacial), associadas com correção atmosférica, foram descartadas. As bandas 2, 4 e 8 foram reamostradas, utilizando o algoritmo de vizinho mais próximo, de 10 para 20 metros de resolução espacial, preservando a resolução espacial da maioria das bandas, especialmente das posicionadas na região da borda vermelha (Tabela 2.1).

Além da reflectância de superfície das bandas do MSI, a fim de se determinar um eventual benefício do uso de índices de vegetação no processo de

classificação, foram selecionados seis IVs (Tabela 4.4), potencialmente úteis no estudo de ambientes semiáridos.

Tabela 4.4 - Índices de vegetação considerados no estudo. Os comprimentos de onda nas equações correspondem aos centros das bandas (nm) do MSI/Sentinel-2A.

Índice	Equação	Referência
EVI	$\frac{2.5 * (\rho_{842} - \rho_{665})}{(\rho_{842} + 6 * \rho_{665} - 7.5 * \rho_{490} + 1)}$	(HUETE et al., 1997)
EVI2	$\frac{2.5 * (\rho_{842} - \rho_{665})}{(\rho_{842} + 2,4 * \rho_{665} + 1)}$	(SCHLEMMERA et al., 2013)
NDVI	$(\rho_{842} - \rho_{665}) / (\rho_{842} + \rho_{665})$	(ROUSE et al., 1973)
NDII1	$(\rho_{842} - \rho_{1610}) / (\rho_{842} + \rho_{1610})$	(KIMES et al., 1981)
NDII2	$(\rho_{842} - \rho_{2190}) / (\rho_{842} + \rho_{2190})$	(KIMES et al., 1981)
OSAVI <sub>[705,740]</sub>	$\frac{1,6(\rho_{740} - \rho_{705})}{(\rho_{740} + \rho_{705} + 0,16)}$	(WU et al., 2008)

Fonte: Produção do autor.

O NDVI (*Normalized Difference Vegetation Index*), proposto por Rouse et al. (1973), foi escolhido por ser o mais frequentemente utilizado na literatura e por sua resposta frente às mudanças do vigor da vegetação (FORMAGGIO; SANCHES, 2017). Apesar das suas limitações, salientadas por Ponzoni e Shimabukuro (2009), tem sido largamente utilizado em estudos de sensoriamento remoto na Caatinga e com bons resultados (COSTA et al., 2002; BARBOSA et al., 2006; PETTA et al., 2013; ERASMI et al., 2014; ABADE et al., 2015; SILVA, P. F. DA et al., 2017).

De maneira análoga ao NDVI, outro índice que utiliza uma relação normalizada entre duas bandas é o NDII1 (*Normalized Difference Infrared Index*), proposto por Kimes et al. (1981) e redefinido como NDII2 por Hardisky et al. (1983). Diferentemente do NDVI, o NDII utiliza dados do infravermelho próximo e do infravermelho de ondas curtas no cálculo da diferença normalizada. Segundo Ponzoni e Shimabukuro (2009), os intervalos espectrais do SWIR são influenciados pelo conteúdo de água das folhas ou de umidade do dossel. Portanto, o NDII é bastante sensível ao estresse hídrico (JACON et al., 2017), sendo, por isso, muito utilizado em trabalhos em regiões áridas e semiáridas,



emulando com boa performance a tendência da precipitação (RODRÍGUEZ-MORENO; BULLOCK, 2014). Neste trabalho, foram utilizadas as relações entre a banda do infravermelho próximo do MSI (banda 8A do MSI na Tabela 2.1) e as duas bandas do infravermelho de ondas curtas do MSI/Sentinel-2, posicionadas em 1610 nm (banda 11) e 2190 nm (banda 12 na Tabela 2.1), para gerar os índices NDII1 e NDII2, respectivamente.

Em função da semelhança e na manutenção da qualidade dos dados, utilizou-se também o índice EVI2, que utiliza apenas duas bandas ao invés das três do EVI (HUETE et al., 1997). O EVI2 foi utilizado por Salimon e Anderson (2017) que, em seu estudo sobre a produtividade (bruta e líquida) da Caatinga frente a mudanças climáticas, verificaram que as anomalias observadas no EVI2 conseguem responder bem aos eventos de anomalias de precipitação, como severas secas, por exemplo.

A fim de se avaliar um índice de vegetação focado na região da borda vermelha, o OSAVI utilizado neste trabalho foi calculado com as bandas de 705 nm e 740 nm (5 e 6) do sensor MSI/Sentinel-2.

#### **4.2.4. Aquisição e tratamento de dados LiDAR**

O levantamento aerotransportado a laser na área de estudo foi realizado nos dias 15, 17 e 25 de setembro de 2014 com a aeronave a 3.000 metros de altitude. Foi utilizado o sensor *Airborne Laser Scanning ALS-60*, fabricado pela *Leica Geosystems*, de 200 kHz (200.000 pontos por segundo), com 4 retornos e um FOV de 75° (LEICA, 2008).


As ortofotos, que foram obtidas juntamente com o levantamento LiDAR, foram capturadas pelo sensor *Airborne Digital Sensor ADS80*, também construído pela *Leica Geosystems*, operando com três bandas espectrais, sendo uma no vermelho (604-664 nm), uma no verde (533-587 nm) e outra no azul (420-492 nm), respectivamente (LEICA, 2011). O voo, para a tomada das fotos, foi realizado nos dias 02 de junho e 24 de agosto de 2014, a altitude de 4.200 metros.

Ambos os produtos (LiDAR e fotografias aéreas) foram unidos e corrigidos pelas empresas Engefoto e Esteio, com precisão planimétrica e altimétrica que atendem ao Padrão de Exatidão Cartográfica (PEC), referente à classe A, na escala 1:5.000 (SECRETARIA DE DESENVOLVIMENTO ECONÔMICO, 2016). A validação da qualidade dos produtos foi realizada pelo Instituto de Tecnologia de Pernambuco (ITEP), disponibilizada pelo projeto PE3D no sistema UTM (Universal Transversa de Mercator) para o SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas), nos fusos 24 sul (SECRETARIA DE DESENVOLVIMENTO ECONÔMICO, 2016).

Os dados foram disponibilizados pelo projeto PE3D sob as formas de modelos digitais de elevação (MDE) e de modelos digitais do terreno (MDT), ambos na resolução de 1 metro. Para este trabalho, o modelo digital do dossel (MDD) foi obtido pela subtração do MDE pelo MDT, conforme realizado em inúmeros trabalhos (CLARK et al., 2004; OMASA et al., 2007; 2008; BEN-ARIE et al., 2009; FELICIANO et al., 2017; SILVA, C. A. et al., 2017; ALEXANDER et al., 2018).

Todas as métricas foram geradas para um pixel de tamanho compatível com os produtos do Sentinel-2, isto é, 20 m. Dessa forma, os pixels das imagens de reflectância foram projetadas nos MDE, MDT e MDD, cujos valores foram calculados em função desta área (Figura 4.2).

Figura 4.2 - Exemplo de projeção do pixel de 20x20 metros do Sentinel-2 sobre o MDD com resolução de 1x1 metro mostrando duas árvores com alturas próximas à 7 metros (uma no topo e outra na base da figura) intercalada por vegetação de menor porte.



Fonte: Produção do autor.

As métricas LiDAR testadas para fins de classificação das fitofisionomias de Caatinga estão indicadas na Tabela 4.5. A partir do MDT, foram geradas métricas que poderiam indicar a predominância das fitofisionomias em determinadas posições e/ou características do relevo, como topos e linhas de drenagem. Algumas destas ocorrências, observadas durante a campanha de campo e em trabalhos como os de Rodal et al. (2008) e de Francisco et al. (2012), podem estar associadas a fatores como acumulação de umidade e nutrientes. Estas métricas foram: altitude, declividade e curvatura do terreno.

Já a partir do MDD, além da própria altura da vegetação, também foi estimado o desvio padrão da altura, a altura máxima, a distância entre os indivíduos arbóreos e as porcentagens de indivíduos arbóreos, arbóreos-arbustivos, arbustivos, subarbustivos e gramíneos lenhosos.

Tabela 4.5 - Métricas LiDAR consideradas neste trabalho.

Métrica	Descrição
Curvatura	Curvatura do terreno calculada a partir do MDT
Declividade	Declividade do terreno calculada a partir do MDT
hVegMax	Altura máxima da vegetação
hVegMed	Altura média da vegetação
hVegSTD	Desvio padrão das alturas da vegetação
MDT	Altitude do terreno
%A	Porcentagem de cobertura arbórea em 400m <sup>2</sup>
%AA	Porcentagem de cobertura arbórea-arbustiva em 400m <sup>2</sup>
%B	Porcentagem de cobertura arbustiva em 400m <sup>2</sup>
%S	Porcentagem de cobertura subarbustiva em 400m <sup>2</sup>
%GL	Porcentagem de cobertura gramínea-lenhosa em 400m <sup>2</sup>

Fonte: Produção do autor.

#### 4.2.5. Classificação Random Forest

Segundo Hodgson (1998), o uso de janelas é comum em classificadores pixel-a-pixel, como o RF, quando se deseja obter, para o pixel central, a informação dos pixels ao redor. Uma vez que a vegetação da Caatinga apresenta uma elevada variabilidade espacial de seus elementos de paisagem, o classificador deve levar em conta o contexto no qual o pixel a ser classificado está inserido.

Por esta razão, todas as imagens (reflectância, IVs e LiDAR) foram submetidas a um filtro de 7x7 pixels, onde foram extraídos os valores de média, mediana, desvio padrão e amplitude. O tamanho da janela foi escolhido após testes com os tamanhos 3x3, 5x5, 7x7 e 9x9 pixels, onde a janela 7x7 foi a que apresentou melhores resultados de classificação.

Todas as métricas selecionadas foram então submetidas ao classificador RF por meio da biblioteca Python Scikit-learn (PEDREGOSA et al., 2012), na IDE (*Integrated Development Environment*) Spyder/Anaconda. Para a classificação, o RF utiliza-se de um número determinado de árvores aleatórias de decisão, formando uma “floresta aleatória”. Cada árvore de decisão possui uma quantidade de nós, que representa cada uma das decisões condicionais existente na árvore.

Para a classificação, foram utilizadas 200 árvores de decisão na floresta aleatória e um número mínimo de quatro nós para cada árvore. Esta escolha dos valores de árvores e nós teve como base a literatura, visto que Rodriguez-Galiano et al. (2012) sugerem que a acurácia aumenta pouco com a escolha de um grande número de árvores. Os mesmos autores confirmaram o aumento da acurácia com menores valores de nós. Desta forma, é preferível usar um grande número de árvores e um menor número de nós a fim de reduzir o erro de generalização e a correlação entre árvores (RODRIGUEZ-GALIANO et al., 2012).

A partir do mapa de referência foram coletados três mil pontos onde, dois terços destinaram-se ao treinamento e um terço à validação (RODRIGUEZ-GALIANO et al., 2012; HEUNG et al., 2016). Finalmente, utilizando o RF, gerou-se seis mapas de fitofisionomias, de acordo com as seguintes estratégias de classificação:

- I – Foram utilizadas as imagens de **reflectância** do MSI/Sentinel-2 referentes ao **período úmido** (14/05/2016);

- II – Foram utilizados os valores de **reflectância** do MSI/Sentinel-2 referentes ao **período seco** (22/08/2016);
- III – O classificador RF foi alimentado com todos os valores de **reflectância** de **todas as datas disponíveis** (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016);
- IV – Utilizou-se na classificação os **IVs** calculados a partir das imagens do MSI/Sentinel-2, **para todas as datas** (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016);
- V – Agregou-se para a classificação todos os valores de **reflectância** e todos os **IVs**, referentes às **quatro datas disponíveis** (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016);
- VI – Além de todos os valores de **reflectância** e todos os **IVs**, referentes às **quatro datas disponíveis** (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016) incorporou-se as **métricas LiDAR**.

As abordagens I e II foram adotadas com dados de reflectância do MSI/Sentinel-2 para verificar se haviam diferenças estatisticamente significantes na precisão de classificação obtida com RF nos períodos chuvoso e seco. A estratégia III foi utilizada para verificar eventuais ganhos do uso de uma abordagem multi-temporal (4 datas) em relação a abordagem mono-temporal (I e II). Testou-se na abordagem IV a performance dos índices de vegetação em relação aos dados de reflectância. Os eventuais ganhos no poder discriminatório com a utilização dos índices de vegetação associados aos dados de reflectância foram considerados na abordagem V. Finalmente, ganhos da adição das métricas LiDAR no processo de classificação RF foram avaliados na abordagem VI.

A partir dos três mil pontos inicialmente coletados usando o mapa de referência, mil pontos foram selecionados para a validação da classificação, estimada por meio do cálculo da acurácia global e do usuário e dos índices kappa, em uma

matriz de confusão, abordagem utilizada por inúmeros autores (MALDONADO et al., 2002; JACON et al., 2017; TONIOL et al., 2017). A fim de embasar a discussão, os índices kappa calculados foram submetidos a testes de significância estatística individualmente, para verificar a relevância da classificação, e em pares, analisando as diferenças de classificação.

As métricas consideradas neste trabalho também foram ranqueadas de acordo com sua importância na classificação, por meio do parâmetro *mean decrease impurity*. Este parâmetro também é conhecido como índice Gini, que de maneira semelhante ao *mean decrease accuracy*, utiliza a permuta aleatória dos valores de uma feição para medir a diminuição da precisão dos dados calculando, assim, sua importância (BREIMAN et al., 1984).

Para cada classificação foram gerados mapas de confiabilidade utilizando a metodologia proposta por Clark e Kilham (2016), onde, num dado pixel  $P_{xy}$ , quanto maior for a quantidade de votos, maior será a confiabilidade do classificador ao atribuir a classe vencedora (CLARK; KILHAM, 2016).

### **4.3. Análise dos atributos físico-químicos do solo**

#### **4.3.1. Levantamento dos dados físicos e químicos do solo**

Para fins de análise de dados, utilizou-se um levantamento detalhado de solos feito por Burgos e Cavalcanti (1990) na porção da área de estudo compreendendo a Embrapa Semiárido. O levantamento incluiu a geração de um mapa de solos (escala 1:7500) e análises físico-químicas detalhadas de amostras coletadas em 75 perfis de solos, com descrição pedológica associada.

No presente trabalho, foram considerados para análise os seguintes parâmetros físico-químicos associados com o horizonte A: espessura do horizonte (cm); % de calhau (grãos > 20 mm); % de cascalho (20 mm > grãos > 2 mm); % de terra fina (grãos < 2 mm); % de areia grossa (2 mm > grãos > 0,2 mm); % de areia fina (0,2 mm > grãos > 0,05 mm); % de silte (0,05 mm > grãos > 0,002 mm); %

de argila (grãos < 0,002 mm); capacidade de campo (CC - %); ponto de murcha permanente (PMP - %); água disponível (%); porosidade (%); pH em água; soma de bases (VS - Cmol/kg); capacidade de troca catiônica (CTC - Cmol/kg); saturação por bases (VV - %); saturação por alumínio  $Al^{+++}$  (%); e a % de carbono orgânico. Além destes atributos do horizonte A, foram ainda considerados a profundidade do calhau em todo o perfil e a profundidade do solo.

As análises laboratoriais foram realizadas segundo a metodologia definida por EMBRAPA (1979), onde as porcentagens de areia (grossa e fina), silte e argila são obtidas a partir do total da terra fina. Da mesma forma, a soma de bases corresponde à soma dos cátions trocáveis ( $Ca^{++}$ ,  $Mg^{++}$ ,  $Na^{++}$  e  $K^{+}$ ), enquanto que a saturação por bases indica qual a proporção das cargas da CTC ocupadas pela soma de bases.

Portanto, um total de 20 atributos físico-químicos dos solos obtidos em amostras coletadas em 75 perfis de solos foram submetidos à Análise por Componentes Principais (ACP), como descrito a seguir.

#### **4.3.2. Análise por componentes principais (ACP)**

No presente estudo, ACP foi aplicada para reduzir a dimensionalidade dos dados e identificar os atributos físico-químicos dos solos responsáveis pela maior parte da variância dos dados em cada componente. Aplicou-se ACP sobre o conjunto de 20 atributos físico-químicos dos solos medidos em 75 amostras ou perfis de solos. O aplicativo IBM SPSS Statistics (versão 25) foi utilizado.

A extração das componentes foi feita com base na matriz de correlação, considerando a diferente gama de atributos e unidades físicas, selecionando-se os autovalores responsáveis pela maior parte da variância acumulada dos dados. A contribuição de cada atributo do solo para explicar cada componente foi determinada da análise da matriz de autovetores. Os testes estatísticos de Kaiser-Meyer-Olkin (KMO) e de esfericidade de Bartlett foram usados para examinar a adequação da amostragem e do tipo de dado para redução de

dimensionalidade, respectivamente, conforme descrito por Cerny e Kaiser (1977). Plotes dos escores das primeiras componentes, sem rotação, foram obtidos e analisados. Uma análise prévia de outliers se baseou na identificação de escores com valores superiores a quatro desvios-padrão da média, cujas amostras correspondentes foram removidas da ACP.

### 4.3.3. Krigagem

Os atributos físico-químicos dos solos mais importantes, detectados da ACP, foram então submetidos à krigagem. Os valores de cada atributo foram interpolados para toda a área do antigo CPATSA. Inicialmente os dados tiveram seus valores de curtose e simetria avaliados a fim de se verificar a necessidade de eventuais transformações nos dados (YAMAMOTO; LANDIM, 2013). Uma vez que os dados não possuíam valores que justificassem qualquer transformação, foi escolhida a krigagem ordinária (YAMAMOTO; LANDIM, 2013). Este tipo de krigagem tem sido bastante utilizado em estudos de solos, como o feito por Vasques et al. (2016), ao interpolar 11 atributos relacionados com carbono, frações granulométricas e água do solo.

Para se modelar o comportamento da dependência espacial, inicialmente foi construído um semivariograma empírico (Equação 4.1), utilizando-se pares de distâncias entre pontos amostrais:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2 \quad (4.1)$$

Onde  $N(h)$  é o número de pares medidos  $Z(X_i), Z(X_i + h)$ , separados por um vetor  $h$ . A partir da construção deste semivariograma empírico, um modelo teórico foi adaptado. Para cada componente ou atributo do solo, o modelo que mais se ajustou foi o exponencial (Equação 4.2):

$$\gamma(h) = C_0 + C \left[ 1 - \exp\left(-\frac{h}{a}\right) \right] \quad (4.2)$$



Onde  $C_0$  corresponde ao valor quando  $\gamma(h)$  quando  $h$  é igual a zero (efeito pepita);  $a$  é a distância onde os valores de  $\gamma(h)$  se aproximam da variância da amostra e se tornam constante (alcance);  $C$  é a diferença entre a variância dos dados (soleira ou patamar) e  $C_0$  (efeito pepita).

Após a definição dos semivariogramas experimental e teórico para cada CP ou atributo, calculou-se, por meio da Equação 4.3, a razão de dependência espacial (RD), que indica o quão forte é a dependência espacial de uma determinada variável. Segundo Cambardella et al. (1994), taxas menores que 25% indicam uma forte dependência espacial; entre 25% e 75% indicam uma moderada dependência espacial; maiores que 75% indicam uma fraca dependência espacial.

$$RD = \left( \frac{C_0}{C_0 + C} \right) 100 \quad ( 4.3 )$$

Feita a verificação de dependência espacial, procedeu-se a interpolação por krigagem ordinária para toda a área do antigo CPATSA usando o software Spring (versões 4.3.3 e 5.5.0).

#### **4.4. Relações entre solo e vegetação**


A fim de testar eventuais relações entre os solos e a formação de fitofisionomias da Caatinga na área de estudos, os perfis de solos foram agrupados de acordo com a fitofisionomia existente em sua localização. Os atributos físico-químicos com maior peso nas três primeiras componentes principais e separados por fitofisionomias foram, então, submetidos a um teste não paramétrico Mann-Whitney-Wilcoxon, dois a dois, para a verificar a existência de diferenças estatisticamente significativas à 5% de confiabilidade.

## 5 RESULTADOS

### 5.1. Caracterização estrutural das fitofisionomias

O mapa de referência da vegetação, gerado a partir da vetorização do mosaico de fotografias aéreas digitais e de observações de campo, é mostrado na Figura 5.1. Seguindo a chave de classificação proposta por Sá (2008), foram identificadas 7 fitofisionomias na área de estudo: Arbórea aberta (Aa), Arbórea rala (Ar), Arbórea-Arbustiva densa (AAd), Arbórea-Arbustiva aberta (AAa), Arbórea-Arbustiva rala (AAr), Arbustiva (B) e Subarbustiva (S). Foram excluídas do mapa as áreas ocupadas por construções, plantios experimentais e pastagens da Embrapa.

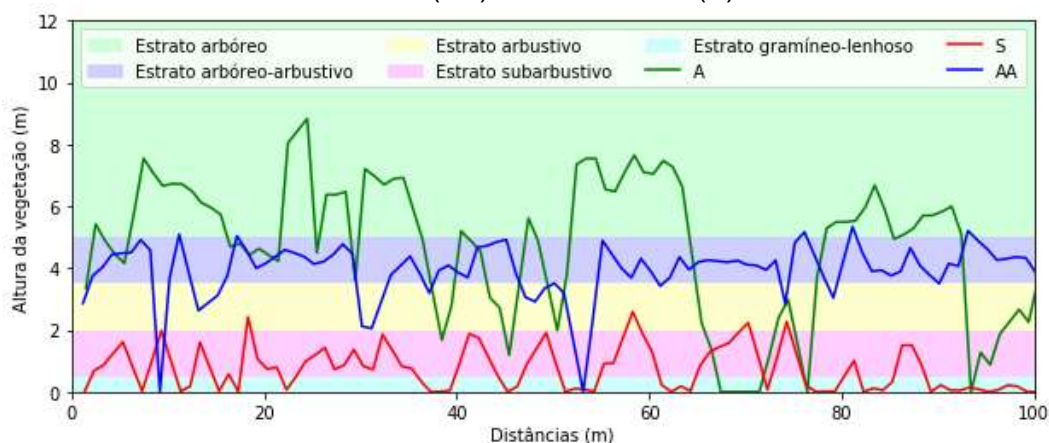
Figura 5.1 - Mapa de referência da vegetação da área de estudo, obtido a partir de fotografias aéreas e de atividades de campo.



Fonte: Produção do autor.

A Figura 5.2 exibe um transecto de 100 metros, obtido a partir dos dados LiDAR, enquanto que a Tabela 5.1 mostra os valores de média e desvio padrão para este mesmo transecto. Na classe Arbórea, é possível observar a sequência de árvores, intercalada por vegetação mais baixa e possuindo, como esperado a maior média de altura. Da classe Arbóreo-Arbustivo para a Subarbustiva, nota-se a transição para uma vegetação herbácea de porte mais baixo, com maior exposição de solo exposto, refletido também nas médias das alturas (3,8 m e 0,8 m respectivamente).

Figura 5.2 - Perfis LiDAR obtidos sobre as principais fitofisionomias de Caatinga da área de estudo, em um transecto de 100 m para as fitofisionomias arbórea (A), arbórea-arbustiva (AA) e subarbustiva (S).



Fonte: Produção do autor.

Tabela 5.1 – Duas métricas LiDAR utilizadas neste trabalho, onde hVeg é a altura média da vegetação e stdVeg é o desvio padrão da altura.


Atributo	A	AA	S
Altura média (m)	4,7	3,8	0,8
Desvio padrão da altura (m)	2,2	1,1	0,7

Fonte: Produção do autor.

Assim, forma-se um gradiente baseado não somente no porte da vegetação, mas também no espaçamento dos indivíduos ou na densidade da cobertura vegetal. A heterogeneidade, tanto da componente horizontal quanto da vertical dos

dosséis, é ilustrada nas fotografias obtidas nas atividades de campo para as diferentes fitofisionomias (Figura 5.3).

Figura 5.3 - Representação das fitofisionomias existentes na área de estudo: Arbórea aberta (Aa), Arbórea rala (Ar), Arbórea-arbustiva densa (AAAd), Arbórea-arbustiva aberta (AAa), Arbórea-arbustiva rala (AAr), Arbustiva (B) e Subarbustiva (S).



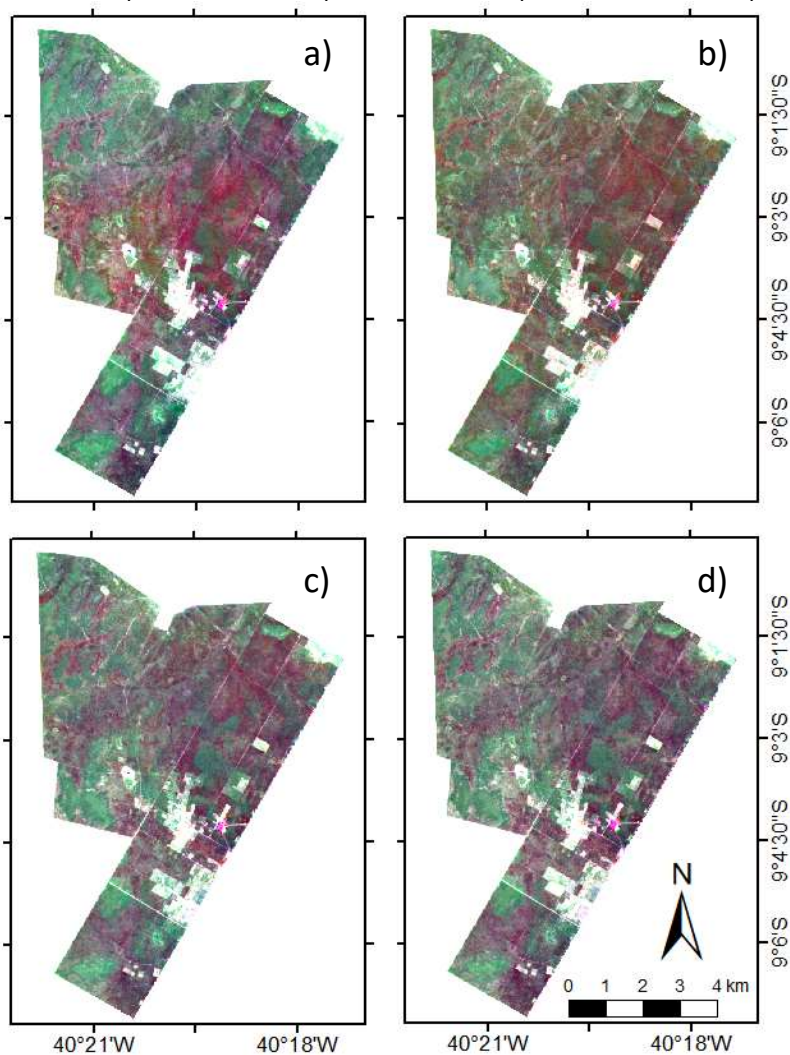
Fonte: Produção do autor.



## 5.2. Caracterização espectro-temporal das fitofisionomias

Uma das características mais marcantes da Caatinga é sua sazonalidade, que repercute no comportamento espectro-temporal da vegetação, visível em imagens orbitais ao longo do ano. A Figura 5.4 mostra uma sequência de imagens de composição colorida falsa cor do sensor MSI/Sentinel-2 para a área de estudo nas quatro datas disponíveis para este trabalho.

Figura 5.4 - Composições coloridas 842 nm (R), 1610 nm (G) e 665 nm (B) para as datas: a) 26/12/2015; b) 14/05/2016; c) 13/07/2016, e; d) 22/08/2016.




Fonte: Produção do autor.

As variações observáveis na análise visual das composições coloridas também são vistas nos espectros de reflectância do sensor MSI/Sentinel-2. Conforme

mostrado na Figura 5.5a, a Caatinga Arbórea (junção das fitofisionomias arbórea aberta (Aa) e arbórea rala (Ar)) possui menores valores de reflectância nas regiões do visível e do infravermelho de ondas curtas do que a Caatinga Subarbustiva, resultado da maior quantidade de folhas e de água no dossel do estrato arbóreo.

Figura 5.5 – Reflectância dos principais grupos de fitofisionomias de Caatinga da área de estudo, medida pelo sensor MSI/Sentinel-2 nos períodos chuvoso (a) e seco (b). Para facilitar a representação gráfica, o desvio padrão é apresentado apenas para a Caatinga arbórea.




Fonte: Produção do autor.

Com o estresse hídrico, que tem início no segundo semestre do ano, a vegetação entra em senescência, aumentando a quantidade de massa seca e a perda de água. Além disso, muitas espécies de árvores são decíduas, perdendo praticamente a totalidade de folhas. O resultado, apresentado na Figura 5.5b, é o aumento dos valores de reflectância para a vegetação arbórea em todas as bandas, em função da menor quantidade de folhas e maior exposição do substrato herbáceo. Por outro lado, a Caatinga Subarbustiva apresenta comportamento muito parecido nas duas épocas consideradas, em função de sua menor sensibilidade ao estresse hídrico e devido ao caráter irregular do regime regional de chuvas.

O comportamento sazonal da vegetação é observado também nos índices de vegetação. As Figura 5.6a, Figura 5.6b e Figura 5.6c mostram a grande diferença sazonal observada para os índices OSAVI<sub>[705,750]</sub>, NDII e NDVI, respectivamente, especialmente entre as classes arbóreas e subarbustivas, nas quatro datas de aquisição das imagens MSI.

Figura 5.6 - Comportamento sazonal dos principais grupos de fitofisionomias de Caatinga para os índices de vegetação OSAVI<sub>[705, 750]</sub> (a), NDII1 (b) e NDVI (c), calculados em quatro datas de aquisição das imagens MSI/Sentinel-2. A precipitação de dezembro de 2015 a agosto de 2016 é apresentada (barras hachuradas) e comparada com médias mensais históricas (1975-2015) (barras pontilhadas). Para facilitar a representação gráfica, o desvio padrão é apresentado apenas para a Caatinga arbórea.



Fonte: Produção do autor.

O OSAVI<sub>[705,750]</sub> indica um verdejamento mais lento para a Caatinga arbórea, de dezembro de 2015 para maio de 2016, com um processo de senescência mais rápido a partir desta data em direção ao período seco. O contrário é observado para a vegetação arbórea-arbustiva, com um verdejamento mais rápido e uma senescência mais lenta (Figura 5.6 a). Um comportamento similar também foi observado com o NDII1 (Figura 5.6 b) e com o NDVI (Figura 5.6 c).

### **5.3. Classificação das fitofisionomias usando Random Forest**

A partir das métricas consideradas nas estratégias de classificação definidas, foram gerados seis mapas de fitofisionomias por meio do algoritmo *Random Forest* com significância estatística a 5%. Todos os mapas foram comparados, por meio de estatística kappa, a pontos aleatoriamente distribuídos no mapa de referência.


#### **5.3.1. Classificações RF nas estações seca e chuvosa**

A fim de se testar eventuais diferenças de classificação nas estações seca e chuvosa, a Estratégia I foi comparada com a Estratégia II, cujo resultado é mostrado na Figura 5.7.

A Tabela 5.2 e a Tabela 5.3 mostram as matrizes de confusão entre o mapa de referência e as classificações das estratégias I e II, respectivamente, estatisticamente iguais a 5%. De forma geral, não houve ganho na classificação ao se optar por imagens no período seco ou chuvoso, exceto para algumas fitofisionomias individualmente. A classificação no período seco privilegiou as classes Ar, Aa, AAr e B em detrimento das classes AAa e S, que tiveram desempenho melhor na classificação da cena de 17/05/2016. Os melhores ganhos para a época seca nas classes arbóreas e arbórea-arbustiva são explicadas pela maior diferenciação de suas reflectâncias (Figura 5.5).



Figura 5.7 – Classificação *Random Forest* usando os dados de refletância do período:  
 a) chuvoso - 14/05/2016 (Estratégia I) e b) seco - agosto de 2016 (Estratégia II).



Fonte: Produção do autor.

Tabela 5.2 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação RF no período chuvoso (Estratégia I).

Classes	Referência								EP (%)	EO (%)
	AAa	AAr	S	Ar	B	Aa	AAd	TOTAL		
<b>AAa</b>	<b>176</b>	47	10	12	28	25	49	347	50,72	49,28
<b>AAr</b>	64	<b>174</b>	16	31	33	36	18	372	46,77	53,23
<b>S</b>	1	2	<b>26</b>	1	1	0	3	34	76,47	23,53
<b>Ar</b>	4	0	0	<b>20</b>	0	5	4	33	60,61	39,39
<b>B</b>	1	1	3	0	<b>32</b>	0	2	39	82,05	17,95
<b>Aa</b>	19	21	2	13	2	<b>43</b>	15	115	37,39	62,61
<b>AAd</b>	15	5	0	10	3	3	<b>24</b>	60	40	60
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	62,86	69,6	45,61	22,99	32,32	38,39	20,87		<b>EG</b>	49%
<b>EI (%)</b>	37,14	30,4	54,39	77,01	67,68	61,61	79,13		<b>Kappa</b>	0,35

Fonte: Produção do autor.

Tabela 5.3 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação RF no período seco (Estratégia II).

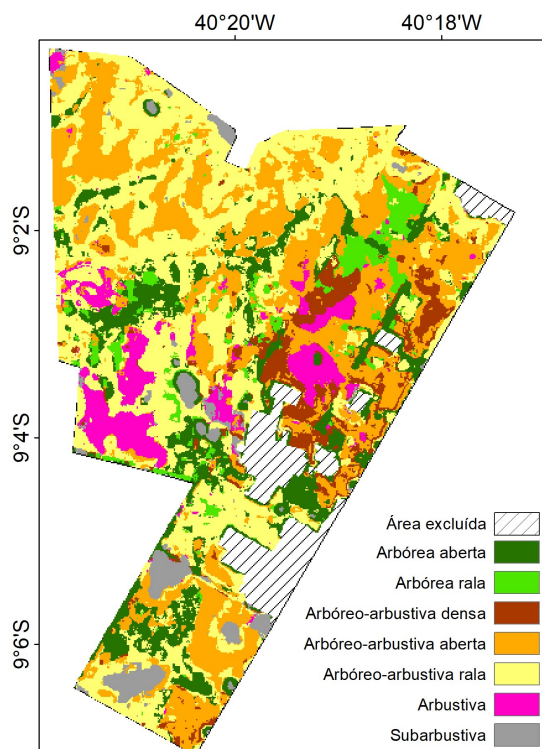
Classes	Referência							TOTAL	EP (%)	EO (%)
	AAa	AAr	S	Ar	B	Aa	AAd			
<b>AAa</b>	<b>151</b>	32	11	16	37	6	41	294	51,36	48,64
<b>AAr</b>	76	<b>190</b>	16	35	16	46	25	404	47,03	52,97
<b>S</b>	4	2	<b>21</b>	0	3	0	1	31	67,74	32,26
<b>Ar</b>	6	5	0	<b>22</b>	2	7	8	50	44	56
<b>B</b>	11	2	7	1	<b>35</b>	1	4	61	57,38	42,62
<b>Aa</b>	19	17	2	10	4	<b>50</b>	12	114	43,86	56,14
<b>AAd</b>	13	2	0	3	2	2	<b>24</b>	46	52,17	47,83
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	53,93	76	36,84	25,29	35,35	44,64	20,87		<b>EG</b>	49%
<b>EI (%)</b>	46,07	24	63,16	74,71	64,65	55,36	79,13		<b>Kappa</b>	0,36

Fonte: Produção do autor.

### 5.3.2. Classificação mono-temporal versus multi-temporal

Quando foram consideradas múltiplas datas na classificação (Estratégia III), observou-se que a utilização de todas as quatro cenas obtidas melhorou a qualidade do mapa, fazendo com que a exatidão global (EG) melhorasse de 49% (Tabela 5.2 e Tabela 5.3), quando utilizando métricas exclusivas do período chuvoso ou do período seco (Figura 5.7a e Figura 5.7b, respectivamente), para 56% (Tabela 5.4), ao se utilizar todas as datas (Figura 5.8). As diferenças estatísticas foram significativas a 5%, de acordo com a estatística Z. Quando se analisou os ganhos de classificação por classe, observou-se melhora nos acertos para todas as fitofisionomias, principalmente para as classes de menor porte de vegetação ou com maior exposição do substrato (S e B).

Figura 5.8 – Classificação RF baseada nos dados de reflectância das quatro datas (26/12/2015, 14/05/2016, 13/07/2016 e 22/08/2016), conforme estratégia III.



Fonte: Produção do autor.


Tabela 5.4 - Matriz de confusão e valores de exatidão global (EG), exatidão do produtor (EP), erros de omissão (EO), exatidão do usuário (EU) e erros de inclusão (EI) para a classificação multi-temporal com dados de reflectância do sensor MSI/Sentinel-2 (Estratégia III).

Classes	Referência							TOTAL	EP (%)	EO (%)
	AAa	AAr	S	Ar	B	Aa	AAAd			
<b>AAa</b>	<b>168</b>	34	7	15	11	5	34	274	61,31	38,69
<b>AAr</b>	64	<b>196</b>	16	30	22	37	23	388	50,52	49,48
<b>S</b>	2	2	<b>29</b>	0	3	0	1	37	78,38	21,62
<b>Ar</b>	4	3	0	<b>25</b>	1	6	2	41	60,98	39,02
<b>B</b>	7	1	4	0	<b>54</b>	1	5	72	75	25
<b>Aa</b>	25	13	1	14	5	<b>60</b>	18	136	44,12	55,88
<b>AAAd</b>	10	1	0	3	3	3	<b>32</b>	52	61,54	38,46
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	60	78,4	50,88	28,74	54,55	53,57	27,83		<b>EG</b> 56%	
<b>EI (%)</b>	40	21,6	49,12	71,26	45,45	46,43	72,17		<b>Kappa</b> 0,45	

Fonte: Produção do autor.

A Figura 5.9 mostra as vinte métricas (do total de 40 métricas) de maior importância, estimada por meio do *mean decrease impurity* (MDI), para o processo de classificação da Estratégia III. Há o destaque para a região do visível, relacionada para as bandas do azul e do vermelho (bandas de absorção da clorofila). A região do SWIR (1 e 2), fortemente relacionada ao conteúdo de água no dossel das plantas, contou com praticamente todas as suas bandas listadas entre as de maior importância.


Figura 5.9 – Ranqueamento das vinte principais métricas para o processo de classificação da estratégia III com base no *Mean Decrease Impurity* (MDI).



Fonte: Produção do autor.

A partir de duas métricas entre as mais bem ranqueadas, foi elaborado um diagrama de espalhamento com a distribuição das fitofisionomias encontradas na área (Figura 5.10). Como pode-se observar, há uma preferência geral das fitofisionomias de menor porte (B e S) em ocuparem posições abaixo da linha de tendência, isto é, com valores maiores de reflectância na região do SWIR 1 e menores na região do vermelho. As fitofisionomias arbóreas (Aa e Ar) localizam-se preferencialmente acima da linha de tendência, com maiores valores de reflectância na região do vermelho e do SWIR 1.


Figura 5.10 - Diagrama de espalhamento das métricas com melhor ranqueamento pelo *Random Forest*, considerando a abordagem multi-temporal com dados de reflectância do MSI/Sentinel-2.



Fonte: Produção do autor.

Na Figura 5.11 nota-se a melhora de classificação com a utilização da abordagem multi-temporal (Estratégia III) em relação a abordagem mono-temporal (Estratégias I e II). Quando comparados com a Estratégia I (período chuvoso), maiores ganhos se deram nas classes B, Aa e S com aumentos das EU de 68,8%, 39,5% e 11,6% respectivamente.

Figura 5.11 - Gráfico com os valores de exatidão do usuário para as classificações RF usando dados de reflectância dos períodos chuvoso (Estratégia I) e seco (Estratégia II) e de todas as quatro datas de aquisição das imagens MSI/Sentinel-2 (Estratégia III).




Fonte: Produção do autor.

### 5.3.3. Classificação RF com índices de vegetação

A Estratégia IV (utilizando exclusivamente os índices de vegetação EVI, EVI2, NDVI, NDII1, NDII2 e OSAVI<sub>[705,740]</sub> das quatro datas consideradas) resultou na classificação exibida na Figura 5.12a, cujos valores de kappa e EG foram maiores que os valores resultantes da classificação oriunda da Estratégia III (reflectância multi-temporal), embora não significativo estatisticamente (Tabela 5.5). De qualquer forma, 24 métricas (seis IVs em quatro datas) produziram resultados iguais estatisticamente à aquela produzida por 40 métricas (dez bandas espectrais em quatro datas) mostrando o poder de síntese dos índices de vegetação.

Figura 5.12 – Classificação RF com a) índices de vegetação multi-temporais (Estratégia IV) e com a combinação de b) dados de reflectância e índices de vegetação multi-temporais do sensor MSI/Sentinel-2 (Estratégia V).



Fonte: Produção do autor.

A Estratégia V (Figura 5.12b), resultado da aglutinação dos conjuntos de métricas utilizadas nas Estratégias III e IV, gerou resultados insignificantes estatisticamente diante de suas estratégias antecessoras (Tabela 5.6). De fato,

comparando a Figura 5.12a com a Figura 5.12b, é possível notar a quase ausência de diferenças visuais entre as classificações obtidas de ambas as estratégias de classificação.

Tabela 5.5 - Matriz de confusão para a classificação RF utilizando índices de vegetação multi-temporais (Estratégia IV).

Classes	Referência								EP (%)	EO (%)
	AAa	AAr	S	Ar	B	Aa	AAAd	TOTAL		
<b>AAa</b>	<b>185</b>	31	8	22	20	13	38	317	58,36	41,64
<b>AAr</b>	45	<b>196</b>	15	28	15	39	22	360	54,44	45,56
<b>S</b>	5	5	<b>29</b>	0	2	0	0	41	70,73	29,27
<b>Ar</b>	5	3	0	<b>25</b>	3	3	3	42	59,52	40,48
<b>B</b>	8	0	4	0	<b>55</b>	2	6	75	73,33	26,67
<b>Aa</b>	22	13	1	12	1	<b>51</b>	16	116	43,97	56,03
<b>AAAd</b>	10	2	0	0	3	4	<b>30</b>	49	61,22	38,78
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	66,07	78,4	50,88	28,74	55,56	45,54	26,09		<b>EG</b>	57%
<b>EI (%)</b>	33,93	21,6	49,12	71,26	44,44	54,46	73,91		<b>Kappa</b>	0,46

Fonte: Produção do autor.

Tabela 5.6 - Matriz de confusão para a classificação RF utilizando a combinação de dados multi-temporais de reflectância e índices de vegetação (Estratégia V).

Classes	Referência								EP (%)	EO (%)
	AAa	AAr	S	Ar	B	Aa	AAAd	TOTAL		
<b>AAa</b>	<b>178</b>	32	6	17	14	7	34	288	61,81	38,19
<b>AAr</b>	58	<b>197</b>	16	28	19	35	22	375	52,53	47,47
<b>S</b>	3	3	<b>28</b>	1	2	0	0	37	75,68	24,32
<b>Ar</b>	3	2	0	<b>27</b>	0	3	1	36	75	25
<b>B</b>	8	1	6	1	<b>59</b>	1	8	84	70,24	29,76
<b>Aa</b>	21	13	1	12	2	<b>63</b>	17	129	48,84	51,16
<b>AAAd</b>	9	2	0	1	3	3	<b>33</b>	51	64,71	35,29
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	63,57	78,8	49,12	31,03	59,6	56,25	28,7		<b>EG</b>	58%
<b>EI (%)</b>	36,43	21,2	50,88	68,97	40,4	43,75	71,3		<b>Kappa</b>	0,48

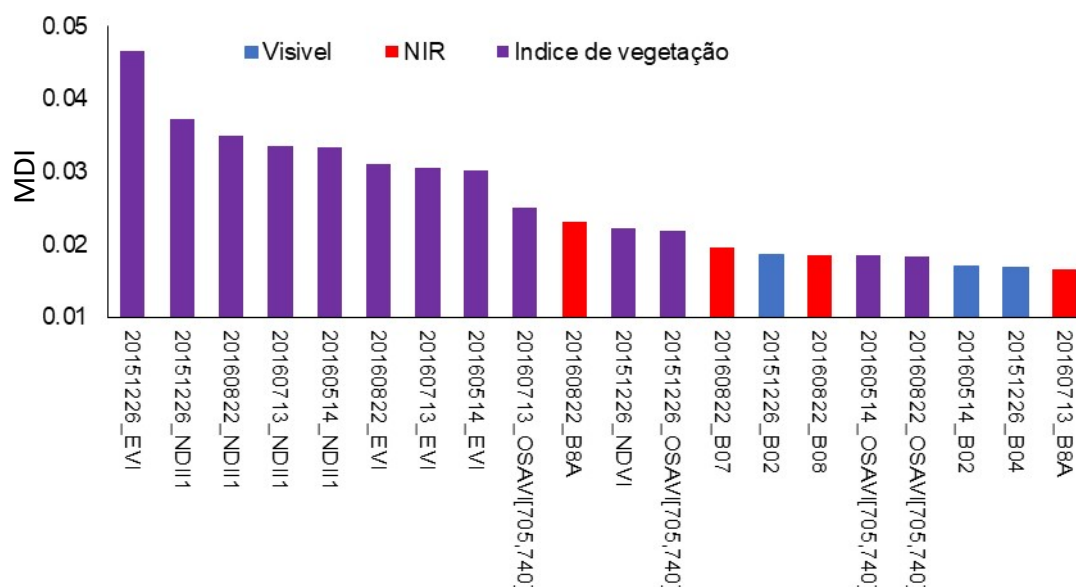
Fonte: Produção do autor.

De acordo com o *mean decrease impurity*, as vinte métricas (do total de X métricas) de maior peso na classificação da Estratégia V são mostradas na Figura 5.13. Constata-se a dominância das métricas relacionadas aos índices de



vegetação, com treze métricas no total, dos quais estão presentes as quatro métricas relativas aos índices EVI, NDII1 e OSAVI<sub>[705,740]</sub>.

Figura 5.13 - Importância das métricas para classificação utilizando todos os dados de reflectância e todos os índices de vegetação (Estratégia V) com base no *Mean Decrease Impurity* (MDI).




Fonte: Produção do autor.

A partir das duas métricas mais importantes, foi elaborado um diagrama de espalhamento (Figura 5.14) que mostra a distribuição das sete fitofisionomias consideradas no trabalho. Neste diagrama, embora não exista um claro agrupamento das classes, é possível notar as classes arbóreas, possuindo maiores valores de NDVI e EVI, e a classe subarbustiva, possuindo menores valores dos mesmos índices. A classe arbustiva é mais dispersa ao longo da linha de tendência.

Quando se observa o ganho que cada classe tem com a incorporação dos índices de vegetação, nota-se que a melhora ocorre na classe Aa (EU aumentando de 45,5 para 56,2 na comparação entre as Estratégias IV e V), com todas as demais classes tendo pouca ou nenhuma alteração nos valores de exatidão do usuário (Figura 5.15).

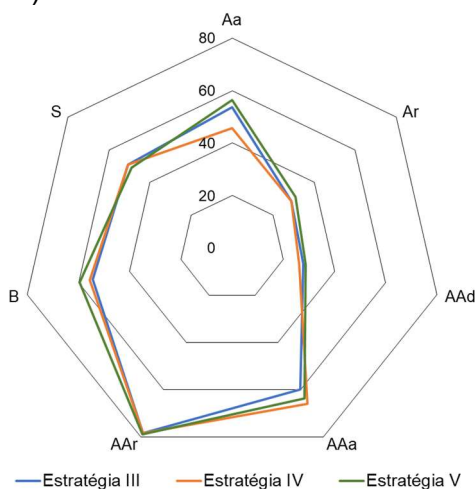


Figura 5.14 - Diagrama de espalhamento dos índices de vegetação NDWI e EVI, ambos para o dia 26/12/2015.



Fonte: Produção do autor.

Figura 5.15 - Gráfico com os valores de exatidão do usuário para as classificações usando os dados de reflectância (Estratégia III), os índices de vegetação (Estratégia IV) e utilizando os dados de reflectância e os índices (Estratégia V).



Fonte: Produção do autor.

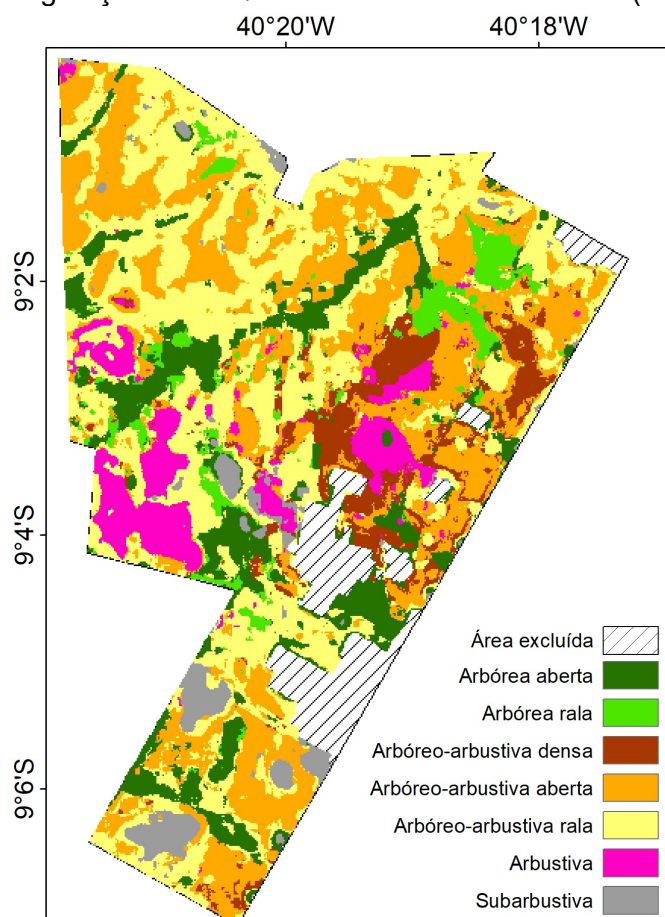
### 5.3.4. Adição de métricas LiDAR na classificação

A Figura 5.16 mostra o mapa de classificação RF da Estratégia VI) com a utilização de todas as métricas do MSI/Sentinel-2, incluindo os dados multi-temporais de reflectância, os dados multi-temporais de IVs e todas as métricas

LiDAR. Observou-se um aumento da exatidão global e do índice kappa (Tabela 5.7) em relação à todas as demais estratégias antecessoras.

Em comparação com a estratégia V, o LiDAR foi responsável pelo aumento de 18,5% para Ar; 11,1% para a Aa; 10,7% para a S; 9,1% para a AAd; 6,2% para a AAa; e 3,4% para a B. Em termos globais, os valores de EG e kappa melhoraram de 58% e 0,48 (Estratégia III) para 61% e 0,51 nesta classificação. As classes arbórea aberta e arbórea rala foram as principais beneficiadas, sendo possível notar a melhor definição dos polígonos em relação ao mapa de referência. Apesar da melhora, as diferenças gerais entre as Estratégias V e VI não foram significantes estatisticamente.

Figura 5.16 – Classificação RF usando dados multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 e métricas LiDAR (Estratégia VI).



Fonte: Produção do autor.

Tabela 5.7 - Matriz de confusão da classificação RF, utilizando os atributos reflectância, índice de vegetação e LiDAR.


Classes	Referência							EP (%)	EO (%)	
	AAa	AAr	S	Ar	B	Aa	AAAd			TOTAL
<b>AAa</b>	<b>189</b>	34	7	19	13	10	37	309	61,17	38,83
<b>AAr</b>	53	<b>196</b>	13	21	21	26	23	353	55,52	44,48
<b>S</b>	3	5	<b>31</b>	0	1	0	0	40	77,5	22,5
<b>Ar</b>	2	1	0	<b>32</b>	1	4	3	43	74,42	25,58
<b>B</b>	5	2	5	0	<b>61</b>	1	6	80	76,25	23,75
<b>Aa</b>	17	10	1	13	1	<b>70</b>	10	122	57,38	42,62
<b>AAAd</b>	11	2	0	2	1	1	<b>36</b>	53	67,92	32,08
<b>TOTAL</b>	280	250	57	87	99	112	115	<b>1000</b>		
<b>EU (%)</b>	67,5	78,4	54,39	36,78	61,62	62,5	31,3		<b>EG</b>	61%
<b>EI (%)</b>	32,5	21,6	45,61	63,22	38,38	37,5	68,7		<b>Kappa</b>	0,51

Fonte: Produção do autor.

A partir da classificação baseada em todo o conjunto de dados, foram listadas as vinte métricas mais expressivas, num total de 75, cujo resultado é mostrado pela Figura 5.17. Nesta seleção, os índices de vegetação contaram com onze métricas entre as mais importantes, e destas, todas as quatro métricas relacionadas ao NDII1 e o EVI estiveram entre as mais bem ranqueadas. Por outro lado, o LiDAR teve sete métricas entre as de maior importância, inclusive uma relacionada ao MDT, que mostra a importância da localização no relevo (topos ou fundos de vales) para as fitofisionomias. Já os valores de reflectância tiveram apenas duas bandas, localizadas na borda vermelha e no NIR do período seco.


A Figura 5.18 mostra o espalhamento das classes de fitofisionomias em função das métricas de percentagem de indivíduos arbóreos e do valor do EVI. O gráfico em questão mostra a boa separabilidade entre os indivíduos arbóreos e os demais grupos, com a primeira ocupando os maiores valores, tanto de EVI quanto de %A.

Figura 5.17 - Importância das métricas multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 e das métricas LiDAR para classificação RF (Estratégia VI) com base no *Mean Decrease Impurity* (MDI).




Fonte: Produção do autor.

Figura 5.18 - Diagrama de espalhamento com os valores das métricas de EVI e de porcentagem de indivíduos arbóreos.



Fonte: Produção do autor.

Figura 5.19 - Gráfico com os valores de acurácia do usuário para a classificação RF usando dados multi-temporais de reflectância e índices de vegetação do MSI/Sentinel-2 (Estratégia V) e a combinação destes dados com métricas LiDAR (Estratégia VI).

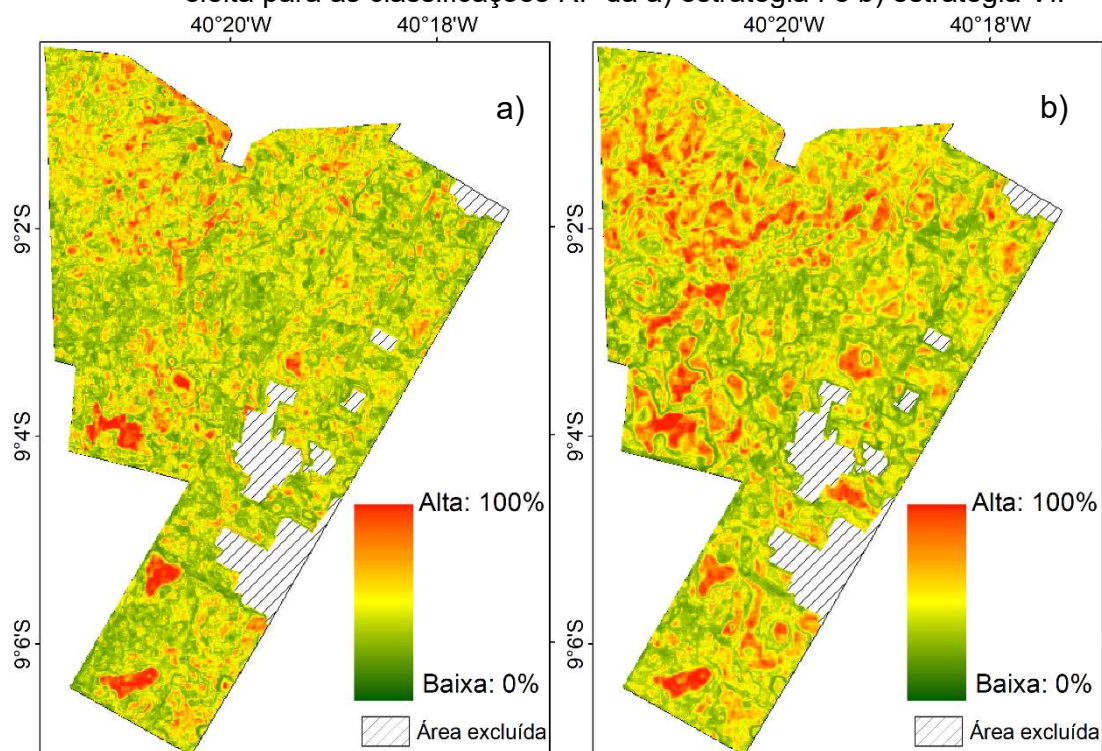


Fonte: Produção do autor.

Por meio do *Random Forest*, é possível estimar a confiança no processo de classificação, pixel a pixel, por meio do cálculo do número de votos recebido pela classe eleita. A Figura 5.20 mostra os mapas de confiança para as estratégias I e VI (baseadas respectivamente nos valores de reflectância para o período chuvoso e utilizando todas as métricas), onde percebe-se o aumento nos valores de confiança em toda a área, com diferenças estatísticas significativas a 5%.

Ao verificar os ganhos por classe de fitofisionomias, o aumento da confiança foi de 22,6%, 5,4%, -0,5%, 11,9%, 8,5%, 13,1%, 3,4% para as classes Aa, Ar, AAd, AAa, AAr, B e S, respectivamente. Comparando as mudanças da EU também entre as Estratégias I e VI, verifica-se que melhoras na classificação não correspondem na mesma medida em melhoras na confiança.

Figura 5.20 – Mapas de confiança de acordo com a porcentagem de votos na classe eleita para as classificações RF da a) estratégia I e b) estratégia VI.



Fonte: Produção do autor.

#### 5.4. Análise por componentes principais (ACP) dos atributos físico-químicos dos solos e espacialização por krigagem

A Tabela 5.8 mostra a matriz do coeficiente de correlação de Pearson para 20 atributos físico-químicos dos solos. Além das altas correlações entre parâmetros proporcionalmente dependentes (percentagens de calhau, cascalho e terra fina, por exemplo), observou-se fortes relações das percentagens de argila e de carbono orgânico com CTC (R igual a 0,83 e 0,82, respectivamente).

Tabela 5.8 - Matriz de correlação de Pearson dos atributos físico-químicos de 75 perfis de solos. As melhores correlações são destacadas em negrito. Os sinais + e # indicam significância a 1% e 5%, respectivamente.

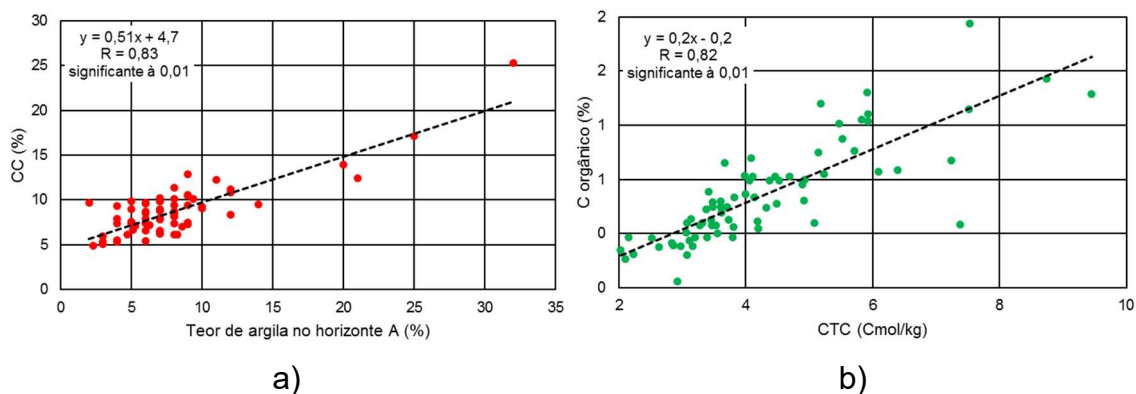
	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	XIII	XIV	XV	XVI	XVII	XVIII	XIX	XX
I	<b>1,00</b>	<b>0,74</b>	0,39	-0,66	<b>-0,70</b>	<b>0,71</b>	-0,01	0,35	-0,17	-0,32	-0,38	-0,38	-0,29	-0,37	-0,10	-0,49	-0,55	-0,09	0,31	-0,52
II	+	<b>1,00</b>	0,40	-0,46	-0,40	0,43	-0,08	0,37	-0,14	-0,34	-0,33	-0,40	-0,14	-0,25	-0,08	-0,41	-0,50	-0,05	0,30	-0,44
III	+	+	<b>1,00</b>	-0,18	-0,26	0,25	0,22	0,01	-0,01	-0,18	-0,25	-0,25	-0,17	-0,24	-0,13	-0,43	-0,45	-0,19	0,44	-0,47
IV	+	+		<b>1,00</b>	<b>0,86</b>	-0,93	0,07	-0,36	0,34	0,16	0,30	0,26	0,28	0,46	0,10	0,47	0,49	0,14	-0,32	0,58
V	+	+	#	+	<b>1,00</b>	<b>-0,99</b>	0,00	-0,32	0,34	0,15	0,28	0,22	0,31	0,45	0,01	0,44	0,47	0,10	-0,27	0,57
VI	+	+	#	+	+	<b>1,00</b>	-0,02	0,34	-0,35	-0,16	-0,30	-0,23	-0,31	-0,47	-0,04	-0,46	-0,49	-0,12	0,29	-0,59
VII			#				<b>1,00</b>	-0,23	-0,33	-0,21	-0,16	-0,14	-0,10	-0,10	0,16	-0,16	-0,24	0,01	0,12	-0,12
VIII	+	+		+	+	+		<b>1,00</b>	-0,61	<b>-0,71</b>	-0,69	-0,68	-0,52	-0,34	0,06	-0,43	-0,50	-0,05	-0,07	-0,31
IX				+	+	+	#	+	<b>1,00</b>	0,24	0,34	0,26	0,36	0,13	-0,13	0,25	0,31	0,01	0,00	0,25
X	+	+						+		<b>1,00</b>	<b>0,83</b>	<b>0,88</b>	0,51	0,45	-0,11	0,54	0,66	0,04	0,01	0,31
XI	+	+	#	#	#	#		+	+	+	<b>1,00</b>	<b>0,92</b>	<b>0,83</b>	0,48	-0,14	0,49	<b>0,73</b>	-0,09	0,06	0,50
XII	+	+	#	#				+	#	+	+	<b>1,00</b>	0,54	0,49	-0,16	0,50	0,76	-0,09	0,06	0,53
XIII	+			#	+	+		+	+	+	+	+	<b>1,00</b>	0,32	-0,02	0,37	0,48	-0,01	0,02	0,31
XIV	+	#	#	+	+	+		+		+	+	+	+	<b>1,00</b>	-0,04	0,50	0,56	0,06	-0,10	0,54
XV															<b>1,00</b>	0,34	-0,15	<b>0,81</b>	-0,58	-0,11
XVI	+	+	+	+	+	+		+		+	+	+	+	+	#	<b>1,00</b>	<b>0,78</b>	0,58	-0,59	0,60
XVII	+	+	+	+	+	+		+	#	+	+	+	+	+		+	<b>1,00</b>	0,01	-0,27	<b>0,82</b>
XVIII			#												+	+		<b>1,00</b>	-0,66	0,00
XIX	+	+	+	+	#	#									+	+	#	+	<b>1,00</b>	-0,29
XX	+	+	+	+	+	+		+	#	+	+	+	+	+	+	+	+		#	<b>1,00</b>

Onde: I é a profundidade do calhau; II é a profundidade do solo; III é a espessura do horizonte A; IV é o teor de calhau; V é o teor de cascalho; VI é o teor de terra fina; VII é o teor de areia grossa; VIII é o teor de areia fina; IX é o teor de silte; X é o teor de argila; XI é a capacidade de campo; XII é o ponto de murcha permanente; XIII corresponde à água disponível; XIV é a porosidade; XV é o pH em água; XVI é o VS; XVII corresponde ao valor da CTC; XVIII corresponde ao VV; XIX é a saturação por alumínio, e; XX é o teor de C orgânico. Onde os valores de I e II correspondem a todo o perfil de solo e os valores de III, IV, V, VI, VII, VIII, IX, X, XI, XII, XIII, XIV, XV, XVI, XVII, XVIII, XIX e XX ao horizonte A.

Fonte: Produção do autor.

As relações entre CC e teor de argila no horizonte A e entre C orgânico e CTC são apresentadas nas Figura 5.21. Para a primeira relação, observa-se um agrupamento dos dados na faixa dos 5% aos 15% para ambos atributos (Figura 5.21a). Quando se compara a umidade a 0,33 atm e o teor de argila (Figura 5.21b), verifica-se um maior espalhamento ao longo da reta diagonal.

Figura 5.21 - Diagramas de espalhamento para as relações entre o teor de argila e a umidade dos solos em (a) e entre o CTC e o conteúdo de carbono orgânico em (b).




Fonte: Produção do autor.

A correlação existente entre os atributos (Tabela 5.8) mostra que a ACP é uma abordagem adequada para melhor entender as relações de variância-covariância dos dados. Utilizando os testes de esfericidade de Bartlett, rejeitou-se a hipótese nula ( $H_0: P_{p \times p} = I_{p \times p}$ ), isto é, que a matriz de correlação teórica é igual à matriz identidade, com  $p$ -valor  $< 0,001$ . Também se verificou a adequação da ACP com a medida KMO próxima a um (0.717). Na ACP utilizada neste trabalho, cerca de 66% de toda a variância acumulada estão nas três componentes principais, com as CP1, CP2 e a CP3 com 39,6%, 15,8% e 10,6% da variância, respectivamente (Figura 5.22).



Figura 5.22 – Percentagem de variância retida pelas componentes principais.

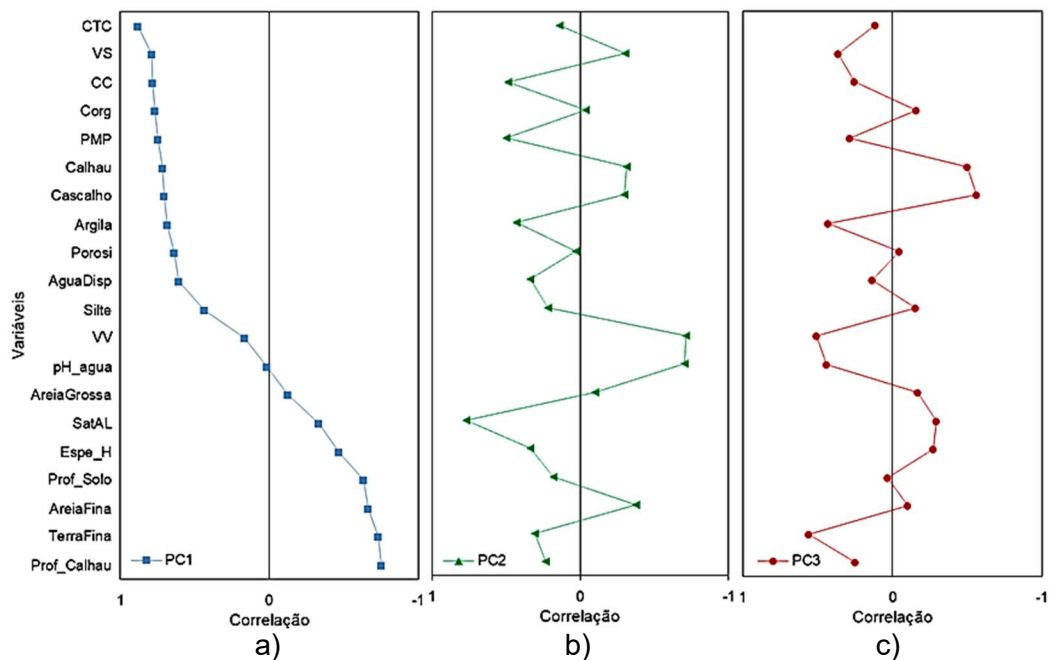


Fonte: Produção do autor.

Analisando os fatores de peso dos autovetores para cada atributo e componente (Figura 5.23), observou-se que a CP1 está associada principalmente com os atributos de fertilidade do solo. Atributos como CTC, soma de bases e carbono orgânico apresentaram fatores de peso altos e positivos (Figura 5.23a), covariando inversamente com a fração terra fina e a profundidade do calhau. Para a CP2, o aumento dos seus valores se traduz em aumento da saturação do alumínio trivalente, ao mesmo tempo em que diminui da saturação por bases, com o aumento da acidez do solo (Figura 5.23b). A CP3 expressa predominantemente a composição das frações do solo, como as porcentagens de cascalho e calhau (fatores de peso negativos na Figura 5.23c) que variam inversamente com a fração terra fina (fatores de peso positivos).


A Figura 5.24 mostra o diagrama de espalhamento para os primeiros dois escores das duas primeiras componentes principais, não apresentando nenhuma tendência clara de organização ou de agrupamento dos pontos.

Figura 5.23 - Gráficos de autovetores dos 20 atributos físico-químicos dos solos nas três primeiras componentes principais.



Fonte: Produção do autor.

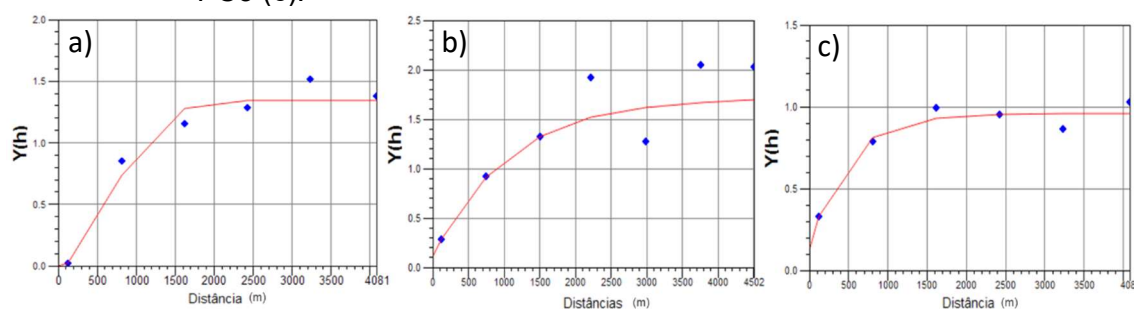
Figura 5.24 - Escores das duas primeiras componentes principais resultantes da ACP aplicada 20 atributos físico-químicos de 75 perfis de solos.



Fonte: Produção do autor.

A partir dos valores das três primeiras componentes principais, os pontos correspondentes aos perfis de solos foram interpolados, por meio da krigagem, gerando um mapa de distribuição. Para a interpolação da primeira componente, a partir do semivariograma experimental, foi utilizado um modelo teórico exponencial cujo valor de Akaike foi de -5,7 e a RD foi igual a 0% (Figura 5.25 a). Para a interpolação dos dados da PC2, foi construído um modelo experimental onde um modelo teórico exponencial foi adaptado, obtendo-se um Akaike de -24,9 e uma RD de 6% (Figura 5.25b). Para os dados da PC3, o modelo que melhor se ajustou também foi o exponencial, que obteve um Akaike de -25.5 e uma razão de dependência espacial igual a 13% (Figura 5.25 c).

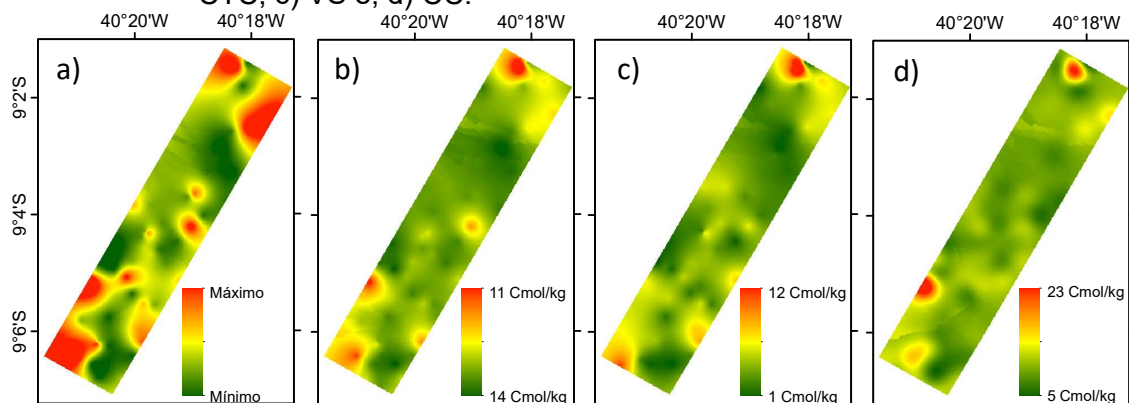
Figura 5.25 - Semivariogramas experimentais e teóricos para as PC1 (a), PC2 (b) e, PC3 (c).



Fonte: Produção do autor.

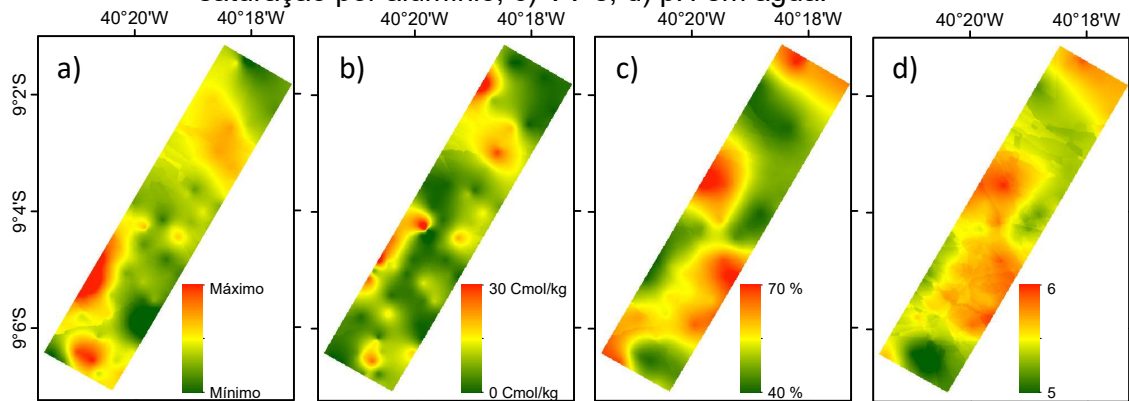
A Figura 5.26 mostra a interpolação da primeira componente e de seus três atributos físico-químicos mais representativos CTC, VS e CC. A Figura 5.27 expõe, além da krigagem da CP2, os atributos saturação de alumínio, VV e pH em água. E a Figura 5.28 mostra a importância de % de cascalho, % de terra fina e VV, como parâmetros a considerar em uma abordagem mais detalhada.

Figura 5.26 - Mapas interpolados por meio da krigagem: a) primeira componente; b) CTC; c) VS e; d) CC.




Fonte: Produção do autor.

Figura 5.27 - Mapas interpolados por meio da krigagem: a) segunda componente; b) saturação por alumínio; c) VV e; d) pH em água.



Fonte: Produção do autor.

Figura 5.28 - Mapas interpolados por meio da krigagem: a) terceira componente; b) % de cascalho; c) % de terra fina e; d) VV.




Fonte: Produção do autor.

## 5.5. Análise da relação entre solo e vegetação

O mapa de fitofisionomias obtido por meio do RF, e com a melhor classificação (Estratégia VI), foi comparado com os atributos de solos selecionados a partir das três primeiras componentes utilizadas neste trabalho (Figura 5.29).

Figura 5.29 – Vista em 3D das distribuições espaciais dos principais atributos relacionados à PC1: a) classificação RF referente à estratégia VI sobre o MDT, b) CTC, c) soma de bases, d) capacidade de campo, e) saturação por  $Al^{+++}$ , f) saturação por bases, g) ponto de murcha permanente, h) % de calhaus, i) % de cascalho, e j) % de terra fina.



Fonte: Produção do autor.

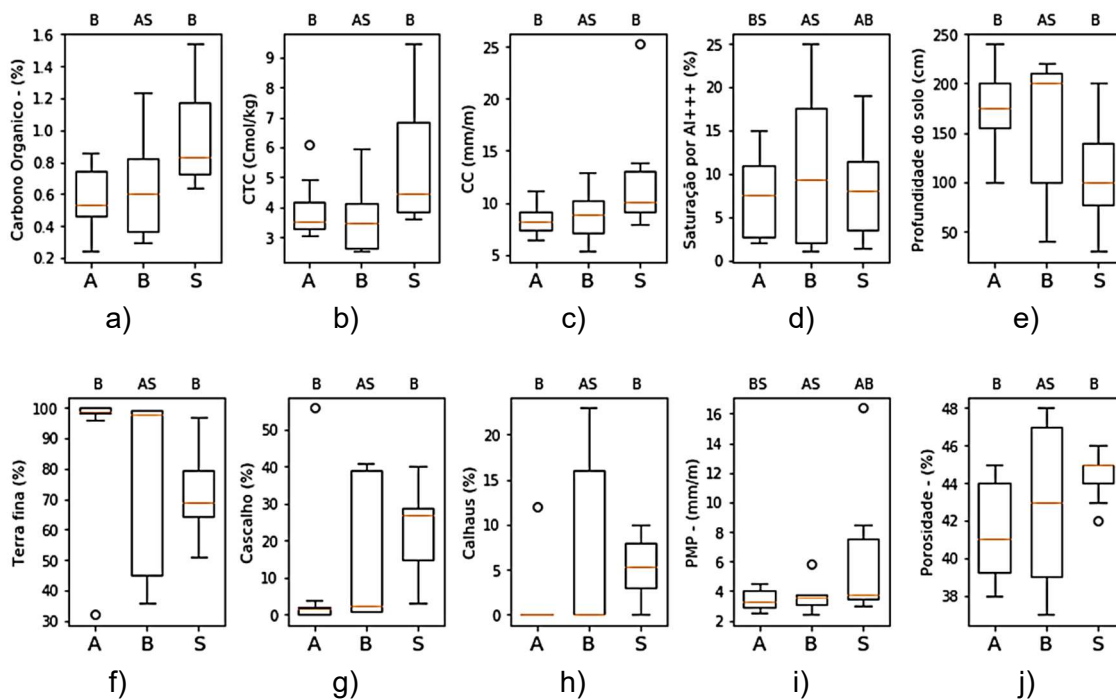
Do ponto de vista da fertilidade no horizonte superficial, as fitofisionomias mais arbóreas parecem menos exigentes, ocupando áreas com menores valores de CTC e soma de bases. Com um sistema radicular mais bem desenvolvido, as árvores podem buscar nutrientes em um volume maior de solo.

Da perspectiva da capacidade de retenção de água, a classe S, em virtude de sua maior dependência dos horizontes superficiais, ocupa preferencialmente solos com maior capacidade de reter e oferecer água (valores maiores de CC e PMP), enquanto que fitofisionomias mais arbóreas, com raízes que atingem camadas inferiores do solo, são menos exigentes com relação à água disponível no horizonte A. Exatamente por isso, a Caatinga subarbustiva opta por solos com textura mais grosseira, com maiores valores de cascalho em relação à terra fina.

Para se estabelecer as relações entre os atributos físico-químicos dos solos e as fitofisionomias, os perfis de solos foram agrupados de acordo com a fitofisionomia em que estavam inseridos. Os atributos físico-químicos dos solos que foram considerados mais relevantes do ponto de vista da variância pela ACP e pertencentes as classes arbóreas (A) arbustivas (B) e subarbustivas (S) tiveram suas distribuições comparadas por meio do teste não paramétrico de Mann-Whitney-Wilcoxon (também conhecido como teste Mann-Whitney U ou MWW).

Suas distribuições e os resultados estatísticos são exibidos na Figura 5.30 sob forma de box-plots, que evidenciaram existir diferenças estatísticas entre as porcentagens de carbono orgânico, CTC, CC, profundidade do solo, calhau, cascalho, terra fina e porosidade.

Figura 5.30 - Box-plot das distribuições dos atributos dos solos a) Carbono orgânico, b) CTC, c) CC, d) saturação por  $Al^{+++}$ , e) profundidade do solo, f) terra fina, g) cascalho, h) calhaus, i) PMP e, j) porosidade para as fitofisionomias arbóreas (A), arbustivas (B) e subarbustivas (S). As letras abaixo do gráfico indicam a classe pertencente do box-plot, enquanto que as letras acima indicam a classe a qual existe igualdade a 5% de significância estatística.



Fonte: Produção do autor.

## 6 DISCUSSÃO

### 6.1. Mapeamento da Caatinga

A Caatinga é um ecossistema bastante complexo com diversos trabalhos associando a elevada variedade de fitofisionomias com características dos solos e clima (ANDRADE-LIMA, 1981; SANTOS et al., 1992; FERRAZ et al., 2003; SILVA, K. A. DA et al., 2009; ARRUDA, 2012). Embora o sensoriamento remoto tenha grande potencial para auxiliar nos estudos deste ecossistema, quando comparado com a Amazônia e o Cerrado, o número de publicações envolvendo dados de sensoriamento remoto na Caatinga é relativamente pequeno. Desta forma, este trabalho buscou contribuir nas discussões referentes ao mapeamento de fitofisionomias e as suas relações com os atributos físico-químicos dos solos, combinando dados do sensor MSI/Sentinel-2 recentemente lançado e de LiDAR, ambos ainda não testados no ecossistema da Caatinga.

A primeira contribuição deste estudo é ressaltar a dificuldade de mapeamento das fitofisionomias da Caatinga, principalmente em nível detalhado utilizando o sensoriamento remoto. Na área de estudo, o mapa de referência (Figura 5.1) mostrou sete fitofisionomias. As duas classes Arbóreas, que ocupam cerca de 20% da área total, estão associadas à rede de drenagem local. Os fundos de vales são ocupados pela Caatinga arbórea mais densa (Aa), enquanto que as formações mais abertas (Ar) se posicionam nas partes mais altas do terreno, sempre próximas entre si. Outros estudos que realizaram mapeamentos de fitofisionomias ou levantamentos florísticos da Caatinga também encontraram configuração semelhante, com o adensamento do componente arbóreo nos fundos de vale (RODAL et al., 2008; FRANCISCO et al., 2012). De forma consistente, uma das métricas LiDAR mais importantes selecionadas pelo classificador RF foi a altitude do terreno, mostrando a importância da posição do relevo para as fitofisionomias de caatinga.

Ainda neste primeiro mapa, observa-se que mais de 60% de toda área foi mapeada como uma das classes de Caatinga Arbórea-arbustiva. De fato,



autores como Burgos e Calvancanti (1990) Feitoza (2013), Souza et al. (2015), definiram genericamente a vegetação da área como “Arbórea-arbustiva”, embora os primeiros tenham reconhecido diversas gradações e particularidades na vegetação da área. Já as classes Arbustivas e Subarbustiva apresentam-se como manchas espalhadas por toda a área, com a última associada também às áreas abaciadas, onde ocorre a formação de pequenas lagoas intermitentes em Vertissolos, observação também feita por Burgos e Cavalcanti, (1990) no levantamento de solos realizado na área de estudo.

A fim de apoiar o processo de separação das diversas classes fitofisionômicas, foram incorporados dados oriundos do LiDAR para oferecer um conjunto de métricas sobre a estrutura da vegetação. De fato, ao observa-se a distribuição da altura da vegetação obtida por meio do LiDAR (Tabela 5.1 e Figura 5.2), notamos a coerência, com as classes Aa e Ar possuindo as maiores médias.

Lima Júnior et al. (2014), ao trabalharem com a estimativa de biomassa lenhosa na Caatinga da área de estudo, coletaram, em 20 parcelas, dados dendrométricos de todas as plantas lenhosas vivas, com diâmetro à altura do peito igual ou maior que 3 cm. Comparando as posições destas parcelas com o mapa de fitofisionomias aqui apresentado, foi possível determinar que estas estavam alocadas em 5 fitofisionomias diferentes. A partir de seu trabalho é possível notar que seus resultados obedecem a mesma hierarquia de alturas aqui encontrada, de modo que se assemelham muito aos dados mensurados pelo LiDAR.

Estas distribuições de alturas afetam sensivelmente a reflectância dos dosséis vegetais ao expor, em maior ou em menor grau, os estratos inferiores e o solo. À primeira vista observou-se o comportamento senoidal da Caatinga ao longo do ano, comportamento típico para vegetação de alta sazonalidade, aparente tanto nos espectros de reflectância (Figura 5.5) quanto nos índices de vegetação (Figura 5.6). Na estação chuvosa, as fitofisionomias com porte arbóreo têm uma maior absorção no vermelho e uma redução da reflectância no infravermelho de

ondas curtas, resultado da absorção de clorofila e água por folhas novas. Com o processo de estiagem, a feição de absorção da clorofila se modifica, ocorrendo um aumento da reflectância em todos os comprimentos de onda medidos pelo sensor. A maior mudança ocorre com a classe das Caatingas arbóreas, em função do aumento da massa seca e da perda de folhas do dossel (deciduidade).

Chaves et al. (2013), estudando índices espectrais obtidos a partir do sensor TM/Landsat-5 para o diagnóstico da Caatinga da bacia do rio Taperoá (PB), encontraram valores absolutos de reflectância na região do vermelho muito próximos aos obtidos neste trabalho, tanto na época seca, quanto na época chuvosa.

Esta característica da sazonalidade foi relatada por diversos autores, como Silva, P. F. DA et al. (2017) que, utilizando duas torres de fluxo, uma em uma área de pastagem e outra em região de Caatinga preservada, obtiveram curvas de IVs semelhantes às observadas neste trabalho para a Caatinga arbórea e Caatinga subarbustiva. Por sua vez, Lima Junior et al. (2014), ao estudarem a relação entre os valores de NDVI obtidos a partir do sensor TM/Landsat-5 e a biomassa medida no campo experimental da Embrapa Semiárido, mostraram que parcelas com estrutura mais arbórea possuem consistentemente maiores valores de NDVI.

Em outro ecossistema brasileiro com elevada sazonalidade, o cerrado brasileiro, a reflectância observada foi semelhante ao observado na Caatinga, como o aumento dos valores no vermelho e na borda vermelha para o período seco (JACON et al., 2017; TONIOL et al., 2017). Entretanto, devido talvez à maior quantidade de folhas secas e troncos, a diferença entre as fitofisionomias no período seco da Caatinga é maior do que no período chuvoso, diferentemente do que foi reportado por Toniol et al. (2017) e Jacon et al. (2017).

Outro ponto importante a respeito dos espectros de reflectância e dos índices de vegetação é o elevado desvio padrão de seus valores, que favorece a confusão entre as classes. Deste modo, ao se comparar classificações mono-temporais

(Figura 5.7) das estações chuvosa (Estratégia I) e seca (Estratégia II), os resultados mostraram que não há diferenças estatisticamente significativas entre os dois períodos (Tabela 5.2 e Tabela 5.3). Contudo, o período seco foi melhor para discriminação de algumas fitofisionomias específicas, com destaque para a Caatinga Arbórea rala, cujo resultado foi 10% maior. Jacon et al. (2017), trabalhando no cerrado brasileiro, também obtiveram melhores resultados de classificação no período seco. Entretanto, Toniol et al. (2017) obtiveram maiores valores de kappa e de exatidão global para a época chuvosa, mas as diferenças entre as classificações de ambos os períodos no cerrado não foram estatisticamente significantes.

No cenário multi-temporal, utilizando-se conjuntamente as quatro datas disponíveis dos dados MSI/Sentinel-2, o ganho de classificação foi sensível, uma vez que o valor de kappa aumentou de 0,39 (período seco) e 0,35 (período chuvoso) para 0,45 (classificação com as reflectâncias das 4 datas). O mesmo ocorreu para a exatidão global, que aumentou de 49% para 56%, com diferenças estatísticas significativas a 5%. Visualmente é possível notar a desfragmentação das classes de menor tamanho, como Aa, B e S, que tiveram melhorias no acerto de classificação.

Em todos os mapas apresentados nesse estudo há uma clara subclassificação das Caatingas B e S, razão pela qual suas áreas aparecem menores que no mapa de referência. As classes das Caatingas arbóreas-arbustivas (AA<sub>d</sub>, AA<sub>a</sub> e AA<sub>r</sub>) foram, em todos os mapas, aquelas que apresentaram maior confusão para o classificador, por serem classes intermediárias na chave de classificação.

A utilização de mais de uma data para auxiliar nos processos de classificação tem se tornado comum na literatura e diversos autores têm reportado melhoras nos índices de acerto ao se mapear fitofisionomias (COLSTOUN et al., 2003; MÜLLER et al., 2015; CLARK; KILHAM, 2016). Hüttich et al. (2011), ao estudarem os efeitos do incremento de imagens nos processos de classificação na região semiárida da Namíbia, concluíram que a acurácia dos mapas aumenta

em função da ampliação do período de observação. Segundo Hüttich et al. (2011), a utilização de conjuntos inter-sazonais também melhora a acurácia da classificação, o que é consistente com os resultados do presente trabalho com a inserção de dados dos períodos chuvoso e seco na análise.

Outro ponto importante diz respeito às classificações criadas a partir dos IVs de todas as datas (Figura 5.12a), onde os valores de exatidão (Tabela 5.4) são praticamente idênticos aos do uso somente de reflectância (Tabela 5.5), não havendo diferenças estatisticamente significantes entre as estratégias de classificação III e IV. Tal resultado é bastante semelhante ao encontrado por Toniol et al. (2017) e por Jacon et al. (2017), mostrando a capacidade dos IVs em melhorar a qualidade de classificação, especialmente da fitofisionomia AAA (Figura 5.15). A estratégia de classificação V (Figura 5.12 b), ao agregar métricas multi-temporais de reflectâncias e índices de vegetação, também não alterou significativamente a precisão de classificação, embora tenha apresentado ganhos principalmente para as Caatingas arbóreas.

A inserção das métricas LiDAR (Figura 5.16) na estratégia VI de classificação produziu diferenças estatísticas significativas (a 5% de significância) em relação às estratégias I, II, III e IV (Tabela 5.7). Quando comparado com a estratégia V, ganhos importantes na exatidão do usuário foram observados para as classes Ar e Aa (aumentos de 18,5% e 11,1%, respectivamente) após a inserção das métricas LiDAR na análise.

A alta variabilidade espacial da Caatinga, bem como sua forte mudança sazonal, transforma o mapeamento de suas fitofisionomias, por meio do sensoriamento remoto, em um desafio. Neste caso, a chave de classificação proposta por Sá (2008), embora detalhada e passível de simplificação, é uma boa opção em estudos de sensoriamento por combinar simultaneamente aspectos associados com a densidade da vegetação e estrutura do dossel. Quando comparado com outras classificações propostas, tais aspectos estão mais próximos das características observadas pelos sensores a bordo de satélites.

A complexidade da distribuição espacial das fitofisionomias de Caatinga e o nível detalhado de legenda adotado no presente trabalho resultou em valores relativamente baixos de acurácia global e de estatística kappa. Fernandes et al. (2015), por exemplo, em seu trabalho na região semiárida de Sergipe, testaram a classificação de dois tipos de fitofisionomias de Caatinga (Caatinga e capoeira), obtendo um kappa de 0,6 e um EG de 82,5%. Por sua vez, Coelho et al. (2014) obtiveram valores de kappa entre 0,9 e 0,8 para classificações de imagens de três anos e com duas classes bastante distintas de Caatinga (Caatinga densa e Caatinga aberta).

Silva e Santos (2011), utilizando imagens ALOS/PALSAR e trabalhando com três tipos fitofisionômicos (arbórea, arbórea-arbustiva e arbustiva), obtiveram exatidão global de 66% e um kappa 0,58. Tal resultado é interessante quando consideramos a capacidade dos dados de radar em mensurar a estrutura da vegetação, tal como ocorre com o LiDAR. Lopes et al. (2013), em seu trabalho mapeando terraços aluvionares, testaram a classificação de três tipos de vegetação de Caatinga (florestada, arbórea-arbustiva e secundária), obtendo, para seu mapa final, um kappa de 0,46.

Por sua vez, Abade et al. (2015), mapeando a fronteira entre a Caatinga e o cerrado, obtiveram 79,06% de exatidão global e 0,74 de kappa com o uso de três classes de vegetação (florestas estacionais decíduas e semi-decíduas e cerrado). Ao utilizarem quatro classes, com a inserção de formações campestres na análise, os valores de exatidão global e de kappa diminuíram para 57,6% e 0,51, respectivamente.

Considerando todas estas publicações no Brasil e o nível detalhado de legenda de classificação utilizado no presente trabalho (sete fitofisionomias), os resultados aqui obtidos podem ser considerados promissores. No leste da Namíbia, em uma vegetação bastante semelhante à Caatinga, Huttich et al. (2011) mostraram o ganho na acurácia da classificação de acordo com o arranjo e a quantidade de imagens utilizadas. Para um arranjo semelhante ao

apresentado neste trabalho, utilizando também o RF, os autores estimam um kappa em torno de 0,5, o que torna os resultados encontrados no presente trabalho bastante compatíveis. Entretanto, quando comparamos as acurácias obtidas por Huttich et al. (2011), para cada uma das classes de vegetação, observamos que os valores obtidos na Caatinga foram superiores, uma vez que o maior número de métricas utilizadas neste trabalho pode ter compensado a menor quantidade de datas.

Outro ponto que merece destaque é que a região nordeste vive, atualmente, uma duradoura seca. Brito et al. (2018), ao estudarem a frequência, duração e severidade de secas no semiárido brasileiro no período de 1981 até os dias atuais, concluíram que a estiagem do período 2011-2016 foi a mais longa e severa. Dentro deste período, o ano de 2013 foi, por exemplo, considerado o pior dos últimos 50 anos (WORLD METEOROLOGICAL ORGANIZATION, 2014). Este longo período de estiagem pode, em muito, ter afetado o processo de classificação, uma vez que, durante a campanha de campo, inúmeras árvores mortas pela estiagem foram encontradas.

Algoritmos como o RF conseguem ranquear suas métricas, o que o torna especialmente interessante nos estudos de ecossistemas complexos como a Caatinga. Analisando e comparando a evolução da influência das métricas no processo de classificação, observou-se que a classificação feita no período chuvoso teve bandas posicionadas nas regiões do infravermelho próximo e do visível como as mais importantes no processo de classificação. No período seco, a reflectância das bandas do NIR teve um peso bastante elevado (40%). Com a utilização das 4 datas disponíveis, os pesos relativos às datas tornaram-se equilibrados, com cada data apresentando métricas com valores de importância em torno de 25%.

Diferentemente dos resultados de Clark e Kilham (2016), onde o infravermelho próximo teve pouco impacto no processo de classificação, o contrário foi observado aqui. Com a inserção dos índices de vegetação, estes passaram a

concentrar 43% da importância relativa no processo de classificação (Figura 5.13), o que é concordante com o trabalho de Clark e Kilham (2016). Mesmo após a incorporação dos dados LiDAR, os IVs continuaram a representar grupo de maior importância dentro do processo de classificação (Figura 5.17). Na somatória geral, o LiDAR somou cerca de 22% da importância relativa, onde 14% referem-se a métricas de vegetação e outros 8% a métricas relacionadas ao terreno, como declividade e altitude, evidenciando também a importância da posição do relevo no processo de distribuição das fitofisionomias.

## **6.2. Análise dos solos**

Outra contribuição deste trabalho corresponde a discussão a respeito dos métodos de análise de interpolação dos atributos físico-químico dos solos. ACP na pesquisa com solos tem sido utilizada há muito tempo com sucesso, uma vez que a técnica tem capacidade para modelar um grande volume de dados. Além da redução na dimensionalidade dos dados, a ACP pode auxiliar na seleção de variáveis, indicando grupos funcionais e quais os parâmetros mais relevantes para caracterizá-los (SENA et al., 2002; HA et al., 2014). Comparando-se os dados de correlação de Pearson deste trabalho (Tabela 5.8) e a correlação obtida por Vasques et al. (2016), é possível verificar que os valores obtidos são bastante próximos, embora entre os dois trabalhos existam diferenças metodológicas significativas. Os resultados encontrados neste trabalho mostram que as CP1, CP2 e a CP3 estavam orientadas a caracterizarem a fertilidade, o equilíbrio entre a saturação entre bases e o alumínio e o componente granulométrico (Figura 5.23), com variâncias iguais a 39,6%, 15,8% e 10,6%, respectivamente (Figura 5.22). Diversos trabalhos na área de solos utilizaram as três componentes, uma vez que a variância acumulada se mostrou mais bem distribuída ao longo das diversas componentes, sendo necessária a utilização de outra componente além das tradicionais duas primeiras (SENA et al., 2002; HA et al., 2014).

A interpolação das componentes tem sido feita nos estudos do solo, como nos trabalhos de Sena et al. (2002), Tavares et al. (2008) e Ha et al. (2014). Para as três componentes principais, a dependência espacial foi considerada forte, uma vez que seus valores ficaram abaixo de 25% (Figura 5.25), tal como preconizam Cambardella et al. (1994). As análises das variâncias da interpolação também se mostraram satisfatórias, mesmo na área da chamada “Ecoteca”, onde havia uma quantidade menor de pontos de amostragem. Os mapas de distribuição da CPs e dos principais atributos constituintes dos solos (Figura 5.26, Figura 5.27 e Figura 5.28) se mostraram coerentes, uma vez que há uma simetria entre as interpolações das CPs e dos atributos do solo, demonstrando que as componentes refletiram bem as variáveis aleatórias originais.

### **6.3. Relações entre atributos físico-químicos do solo e fitofisionomias de Caatinga**

A última contribuição dada por este trabalho é a respeito das relações entre os solos e as fitofisionomias. O primeiro ponto importante a ressaltar é que a área de estudo é dominada em grande parte pela ocorrência de um único tipo de solo (Figura 3.3). Apesar disso, relações estatisticamente significativas foram observadas entre alguns atributos físico-químicos presentes nas classes arbóreas, arbustivas e subarbustivas (Figura 5.29). Diversos foram os trabalhos que estabeleceram qualitativamente associações entre os solos e a vegetação da Caatinga desde a publicação feita por Andrade-Lima (1981). Um dos poucos trabalhos usando uma abordagem quantitativa, produzido por Farias et al. (2016), ao estudar dois tipos de Caatinga arbóreas (densa e aberta), encontrou diferenças estatisticamente significativas entre os teores de  $Al^{+++}$  nos ambientes de Caatinga estudados pelos autores. No presente estudo não se testou a diferença nos valores de  $Al^{+++}$ , mas sim sua saturação na CTC, não havendo diferenças estatísticas (Figura 5.30d). De qualquer forma, a partir dos perfis coletados por Burgos e Cavalcanti, (1990), é possível perceber que áreas de Caatinga aberta contêm teores de  $Al^{+++}$  semelhantes aos encontrados em áreas de Caatinga mais densa ( $0,3 \text{ Cmol/kg} \pm 0,29$ ), embora a ocorrência de maiores



teores de alumínio possam se apresentar como limitante, principalmente associados a outros fatores.

A CTC e o carbono orgânico, propriedades importantes relacionadas à fertilidade do solo, tiveram diferenças estatisticamente significativas entre as Caatingas A e S (Figura 5.30a e Figura 5.30b). Para Tongway e Ludwig, (1990), em seu estudo sobre padrões entre a solos e vegetação para a região semiárida da Austrália, matéria orgânica no solo contribui fortemente para a CTC do solo nos horizontes superficiais do solo. Entretanto, para os mesmos autores, os maiores valores de CTC estão atrelados à vegetação mais arbóreas. Para outros parâmetros atrelados a fertilidade, como soma e saturação por bases, não se encontrou significância estatística entre as diferenças.

No trabalho produzido por Farias et al. (2016), ao estudar dois tipos de Caatinga arbóreas (densa e aberta), os autores encontraram diferenças na pedregosidade, com maiores valores observados em área de vegetação mais esparsa. No presente estudo também foram encontradas diferenças estatísticas nas frações da amostra total (calhaus, cascalho e terra fina; Figura 5.30f, Figura 5.30g e Figura 5.30h) mas, diferentemente de Farias et al. (2016), as Caatingas mais arbóreas se concentraram nas áreas com menor quantidade de calhau e maior quantidade de terra fina (Figura 5.30). Essa discordância também foi encontrada por Shepard et al. (2015) que, ao estudarem os desertos do sudeste dos Estados Unidos, encontraram relações antagônicas entre as texturas superficiais do solo e a biomassa acima do solo. Em um dos desertos, os autores relacionaram a baixa produtividade à textura fina dos solos pelo impedimento da infiltração de água e conseqüente perda da umidade para a atmosfera. Em outro deserto, a textura mais grosseira do solo foi associada a uma menor biomassa, que seria resultado da perda de água devido a drenagem profunda e da diminuição da água disponível na zona de raízes.

Outro ponto que merece consideração refere-se à profundidade do solo (com diferenças estatísticas entre as fitofisionomias A e S) que parece comportar-se

como limitante ao desenvolvimento de vegetação arbórea, restrita a solos com mais de um metro de profundidade (Figura 5.30e). Pinheiro et al. (2013), estudando a zona de raízes de três associações de solo-vegetação (tipicamente arbóreas e arbóreas-arbustivas), concluíram que a profundidade efetiva das raízes oscilava entre 0,60 e 0,78 m para solos sem restrições de profundidade, com variações em torno de 10 cm entre as estações secas e chuvosas. Desta forma, uma limitação em torno de um metro para o desenvolvimento satisfatório do sistema radicular de indivíduos arbóreos parece ser razoável. Para os mesmos autores, ao estudarem solos mais rasos (0,36m), a altura do componente arbóreo se situou por volta dos 5 m, já no limite entre as classes arbórea e arbórea e arbórea-arbustiva.

Finalmente, a infiltração e a retenção da água no solo (principalmente nas camadas mais superficiais) parecem ser fundamentais para o desenvolvimento das espécies de porte menor. Costa et al. (2016) estudaram a oferta de água na zona de raízes em solos da região semiárida ao longo do ano. Eles concluíram que solos rasos possuem menos meses com valores de água no solo abaixo do ponto de murcha, resultado da menor infiltração para níveis mais profundos do solo. Neste trabalho foram encontradas diferenças significativas estatisticamente da capacidade de campo (e também da porosidade), com maiores CC nas áreas de Caatinga subarbustiva (Figura 5.30c e Figura 5.30j).

## 7 CONCLUSÃO

Como mencionado anteriormente, os trabalhos desenvolvidos na Caatinga são um verdadeiro desafio sob o ponto de vista de classificação detalhada das fitofisionomias. Por esta razão, dentre as estratégias de classificação testadas com imagens do MSI/Sentinel-2, é possível concluir que há uma clara vantagem da abordagem multi-temporal em detrimento da mono-temporal, independente do período de aquisição das imagens (chuvoso ou seco). A utilização de IVs também é importante para fins de classificação, permitindo a substituição dos dados de reflectância, por um número menor de arquivos sem redução dos valores de kappa e EG.

Os dados LiDAR também melhoraram o desempenho do classificador RF, principalmente para diferenciar as classes arbóreas de Caatinga. Portanto, o uso de dados multi-temporais do sensor MSI/Sentinel-2, obtidos em quatro datas de 2015 a 2016 (período chuvoso e seco), em combinação com observações LiDAR, melhorou a precisão da classificação das fitofisionomias.

RF possui um bom potencial de classificação em vegetações complexas, como a Caatinga, pois permite a incorporação de uma elevada quantidade de dados e o ranqueamento das melhores métricas no processo de classificação, tudo isto com baixo tempo de processamento. Entretanto, por ser um algoritmo de classificação pixel-a-pixel, a utilização de filtros para captar a variância do entorno é fundamental. O uso de janelas de pixels resulta em melhorias significantes na classificação.

Para a caracterização dos solos, a utilização da técnica de ACP auxiliou no ranqueamento dos atributos físico-químicos mais importantes, reduzindo a quantidade de dados submetidos à krigagem e auxiliando na sua comparação entre as fitofisionomias.

Uma vez que foram encontradas diferenças estatísticas para CTC, carbono orgânico, profundidade do solo, CC, porosidade e nas distribuições de calhau,

terra fina e cascalho, as Caatingas aparentemente se organizam com base na fertilidade, na infiltração e na disponibilidade de água e na profundidade do solo.

Portanto, aceitou-se a hipótese de que existe uma associação entre os atributos físico-químicos, medidos em Argissolos Vermelho-Amarelo do campo experimental da Embrapa Semiárido, e a distribuição espacial de fitofisionomias da Caatinga. Apesar disso, é muito provável que outros fatores possam ser determinantes para a formação de determinadas fitofisionomias, principalmente quando em associação com outros fatores pedológicos, climáticos e/ou botânicos.

Embora na área de estudo exista a predominância de apenas um único tipo de solo, as diferenças entre suas características físico-químicas, em combinação com fatores climáticos, permitiram a formação de diferentes fitofisionomias de Caatinga. Isto demonstra a importância da interação entre clima, solo e vegetação no ambiente da Caatinga.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABADE, N. A.; DE CARVALHO, O. A.; GUIMARÃES, R. F.; DE OLIVEIRA, S. N. Comparative analysis of MODIS time-series classification using support vector machines and methods based upon distance and similarity measures in the brazilian cerrado-Caatinga boundary. **Remote Sensing**, v. 7, n. 9, p. 12160–12191, 2015.
- ACCIOLY, L. C. O.; SILVA, E. A.; CAVALCANTI JUNIOR, E. A.; ALVES, E. A.; PEREIRA, A. G. S.; SILVA, R.S.; RAMOS, R. R. D.; SILVA, R. R. **Mapeamento do uso e cobertura das terras do semiárido pernambucano: (escala 1:100.000)**. Rio de Janeiro: Embrapa Solos, 2017. 100p.
- 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**, p. 885–891, 1995.
- ALEXANDER, C.; KORSTJENS, A. H.; HILL, R. A. Influence of micro-topography and crown characteristics on tree height estimations in tropical forests based on lidar canopy height models. **International journal of applied Earth observation and geoinformation**, v. 65, p. 105–113, 2018.
- ALMEIDA, A. Q.; MELLO, A. A. DE; NETO, A. L. D.; FERRAZ, R. C.; DÓRIA NETO, A. L.; FERRAZ, R. C. Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. **Pesquisa Agropecuaria Brasileira**, v. 49, n. 4, p. 306–315, abr. 2014.
- ALMEIDA, C. L. **Relações solo-planta-atmosfera em Caatinga preservada: o caso da bacia experimental de Aiuaba**. 2016. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal do Ceará, Fortaleza, 2016.
- ALVES, J. S.; COELHO, W. S.; SILVA, R. C. S.; PORTO, D. D.; KIILL, L. H. P. Levantamento fitossociológico em área de Caatinga em diferentes estádios de conservação, em Petrolina, PE. In: JORNADA DE INICIAÇÃO CIENTÍFICA DA EMBRAPA SEMIÁRIDO, 12., 2017, Petrolina. **Anais...** Petrolina: [S.N.], 2017. p. 249–255.

- AMARAL, F. C. S. (Org.). **Sistema brasileiro de terras para irrigação: enfoque na região semiárida**. Rio de Janeiro: Embrapa Solos, 2011.
- ANDERSON, K. E.; GLENN, N. F.; SPAETE, L. P.; SHINNEMAN, D. J.; PILLIOD, D. S.; ARKLE, R. S.; MCILROY, S. K.; DERRYBERRY, D. W. R. Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial lidar and machine learning. **Ecological Indicators**, v. 84, p. 793–802, 2018.
- ANDRADE-LIMA, D. The Caatingas dominium. **Revista Brasileira de Botânica**, v. 4, n. 1, p. 149–163, 1981.
- ARAÚJO FILHO, J. C.; BURGOS, N.; LOPES, O. F.; SILVA, F. B. R. Levantamento de reconhecimento de baixa e média intensidade dos solos do estado de Pernambuco. **Boletim de Pesquisa**, v. 11, p. 382, 2000.
- ARAÚJO FILHO, J. C.; GOMES, E. C.; SILVA, F. H. B. DA; OLIVEIRA NETO, M. B. DE; PARAHYBA, R. D. B. V.; CUNHA, T. J. F.; CAVALCANTI, A. C.; SANTOS, J. C. P.; SILVA, A. B.; LOPES, O. F.; LEITE, A. P.; SILVA, M. S. L.; RIBEIRO FILHO, M. R.; ACCIOLY, L. J. O.; MARQUES, F. A.; AMARAL, A. J.; LIMA, P. C.. **Levantamento de reconhecimento de baixa e média intensidade dos solos do estado de Alagoas**. Recife: Embrapa Solos, 2012.
- ARRUDA, D. M. **Gradientes edáficos e sua relação com as fitofisionomias do semi-árido meridional**. 2012. 69p. Dissertação (Mestrado em Botânica) - Universidade Federal de Viçosa, Viçosa, 2012.
- ASCHBACHER, J.; BEER, T.; CICCOLELLA, A.; PILAR MILAGRO, M.; PALIOURAS, E. Observing Earth, for a safer planet GMES space component: status and challenges. **European Space Agency Bulletin**, v. 2010, n. 142, p. 22–31, 2010.
- ASCHBACHER, J.; MILAGRO-PÉREZ, M. P. The european Earth monitoring (GMES) programme: status and perspectives. **Remote Sensing of Environment**, v. 120, n. 2012, p. 3–8, 2012.
- BALLÉN, L. A. C.; SOUZA, B. I.; DE LIMA, E. R. V. Análise espaço-temporal da

cobertura vegetal na área de proteção ambiental do Cariri, Paraíba, Brasil.

**Boletim Goiano de Geografia**, v. 36, n. 3, p. 555–571, 2016.

BARBOSA, H. A.; HUETE, A. R.; BAETHGEN, W. E. A 20-year study of NDVI variability over the northeast region of Brazil. **Journal of Arid Environments**, v. 67, n. 2, p. 288–307, 2006.

BARTLETT, M. S. Tests of significance in factor analysis. **British Journal of Statistical Psychology**, v. 3, n. 2, p. 77–85, 1950.

BEN-ARIE, J. R.; HAY, G. J.; POWERS, R. P.; CASTILLA, G.; ST-ONGE, B. Development of a pit filling algorithm for LiDAR canopy height models. **Computers and Geosciences**, v. 35, n. 9, p. 1940–1949, 2009.

BERGEN, K. M.; GOETZ, S. J.; DUBAYAH, R. O.; HENEGBRY, G. M.; HUNSAKER, C. T.; IMHOFF, M. L.; NELSON, R. F.; PARKER, G. G.; RADELOFF, V. C. Remote sensing of vegetation 3-D structure for biodiversity and habitat: review and implications for lidar and radar spaceborne missions. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. 4, p. 1–13, 2009.

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

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

BOUAZIZ, M.; MATSCHULLAT, J.; GLOAGUEN, R. Improved remote sensing detection of soil salinity from a semi-arid climate in northeast Brazil. **Comptes Rendus - Geoscience**, v. 343, n. 11–12, p. 795–803, 2011.

BRAGA, E. L.; LEITE, F. A. B.; MOTA, F. O. B.; LEITE, F. R. B.; CHAVES, L. C. G.; BARRETO, M. M. S.; OLIVEIRA NETO, M. B.; BARRETO, R. N. C.;

CUNHA, S. F.; OLIVEIRA, S. B. P. Mapeamento de solos utilizando técnicas de geoprocessamento. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 3605–3611.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE. CADASTRO NACIONAL DE UNIDADES DE CONSERVAÇÃO. **Unidades de conservação por bioma.** Brasília: MMA, 2012.

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

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and regression trees.** Boca Raton: CRC Press, 1984. 366p.

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

BURGOS, N.; CAVALCANTI, A. C. Levantamento detalhado dos solos da área de sequeiro do CPATSA, Petrolina, PE. **Boletim de Pesquisa**, v. 38, n. 38, p. 145, 1990.

CABELLO, J.; ALCARAZ-SEGURA, D.; FERRERO, R.; CASTRO, A. J.; LIRAS, E. The role of vegetation and lithology in the spatial and inter-annual response of evi to climate in drylands of southeastern Spain. **Journal of Arid Environments**, v. 79, p. 76–83, 2012.

CALIXTO JÚNIOR, J. T.; DRUMOND, M. A. Estudo comparativo da estrutura fitossociológica de dois fragmentos de Caatinga em níveis diferentes de conservação. **Pesquisa Florestal Brasileira**, v. 34, n. 80, 2014.

CALIXTO JÚNIOR, J. T.; DRUMOND, M. A.; ALVES JÚNIOR, F. T. Estrutura e distribuição espacial de mimosa tenuiflora (willd.) poir. em dois fragmentos de Caatinga em Pernambuco. **Revista Caatinga**, v. 24, n. 2, p. 95–100, 2011.

CAMBARDELLA, C. A.; MOORMAN, T. B.; PARKIN, T. B.; KARLEN, D. L.;



- NOVAK, J. M.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, v. 58, n. 5, p. 1501, 1994.
- CARRIÓN, J. F.; GASTAUER, M.; MOTA, N. M.; MEIRA-NETO, J. A. A. Facilitation as a driver of plant assemblages in Caatinga. **Journal of Arid Environments**, v. 142, p. 50–58, 2017.
- CARVALHO, J. R. P.; SILVEIRA, P. M.; VIEIRA, S. R. Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. **Pesquisa Agropecuária Brasileira**, v. 37, n. 8, p. 1151–1159, ago. 2002.
- CARVALHO, T. R. A.; ALMEIDA, C. L.; ALMEIDA, A. M. M.; PORTO, M. F.; ARAÚJO, J. C.. Índice de área foliar em Caatinga preservada. **Conexões - Ciência e Tecnologia**, v. 11, n. 1, 1 mar. 2017.
- CERNY, B. A.; KAISER, H. F. A study of a measure of sampling adequacy for factor-analytic correlation matrices. **Multivariate Behavioral Research**, v. 12, n. 1, p. 43–47, jan. 1977.
- CHAVES, I. D. B.; FRANCISCO, P. R. M.; LIMA, E. R. V. DE; SILVA, B. B.; BRANDAO, Z. N.; CHAVES, L. H. G. Índices espectrais, diagnóstico da vegetação e da degradação da Caatinga da bacia do rio Taperoá-PB. In: SILVA, B. B. (Org.). **Aplicações ambientais brasileiras de geoprocessamento e sensoriamento remoto**. Campina Grande: EDUEFG, 2013. p.1–31. Disponível em: <<http://www.alice.cnptia.embrapa.br/handle/doc/977328>>.
- CLARK, M. L.; CLARK, D. B.; ROBERTS, D. A. Small-footprint lidar estimation of sub-canopy elevation and tree height in a tropical rain forest landscape. **Remote Sensing of Environment**, v. 91, n. 1, p. 68–89, 2004.
- CLARK, M. L.; KILHAM, N. E. Mapping of land cover in northern California with simulated hyperspectral satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 228–245, 2016.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3.

**International Journal of Applied Earth Observation and Geoinformation**, v. 23, n. 1, p. 344–351, ago. 2013.

COELHO, M. R.; DART, R. O.; VASQUES, G. M.; TEIXEIRA, W. G.; OLIVEIRA, R. P.; BREFIN, M. L. M.; BERBARA, R. L. L. Levantamento pedológico semi-detalhado (1:30.000) do parque estadual da mata seca, município de Manga - MG. **Boletim de Pesquisa e Desenvolvimento**, v. 217, p. 264, 2013.

COELHO, V. H. R.; MONTENEGRO, S.; ALMEIDA, C. N.; SILVA, B. B.; OLIVEIRA, L. M.; GUSMÃO, A. C. V.; FREITAS, E. S.; MONTENEGRO, A. A. Alluvial groundwater recharge estimation in semi-arid environment using remotely sensed data. **Journal of Hydrology**, v. 548, p. 1–15, 2017.

COELHO, V. H. R.; MONTENEGRO, S. M. G. L.; ALMEIDA, C. N.; LIMA, E. R. V; NETO, A. R.; MOURA, G. S. S. Dinâmica do uso e ocupação do solo em uma bacia hidrográfica do semiárido brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 64–72, 2014.

COLSTOUN, E. C. B.; STORY, M. H.; THOMPSON, C.; COMMISSO, K.; SMITH, T. G.; IRONS, J. R. National park vegetation mapping using multitemporal Landsat 7 data and a decision tree classifier. **Remote Sensing of Environment**, v. 85, n. 3, p. 316–327, 2003.

CORNER, R. J.; DEWAN, A. M.; HASHIZUME, M. Modelling typhoid risk in Dhaka metropolitan area of Bangladesh: the role of socio-economic and environmental factors. **International Journal of Health Geographics**, v. 12, n. 1, p. 1, 2013.

COSTA, C. A. G.; ARAUJO, J. C.; LOPES, J. W. B.; PINHEIRO, E. A. R. Permanence of water effectiveness in the root zone of the Caatinga biome. **Revista Caatinga**, v. 29, n. 3, p. 692–699, 2016.

COSTA, T. C. E. C.; ACCIOLY, L. J. O.; OLIVEIRA, M. A. J. ; BURGOS, N.; SILVA, F. H. B. B. Phytomass mapping of the “seridó Caatinga” vegetation by

the plant area and the normalized difference vegetation indices. **Scientia Agricola**, v. 59, n. 4, p. 707–715, 2002.

CUNHA, J. E. B. L.; RUFINO, I. A. A.; SILVA, B. B.; CHAVES, I. B. Dinâmica da cobertura vegetal para a bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 5, p. 539–548, 2012.

D'OLIVEIRA, M. V. N.; FIGUEIREDO, E. O.; PAPA, D. A. **Uso do lidar como ferramenta para o manejo de precisão em florestas tropicais**. Brasília: Embrapa Acre, 2014. 132p. Disponível em: <<https://www.embrapa.br/acre/busca-de-publicacoes/-/publicacao/1029435/uso-do-lidar-como-ferramenta-para-o-manejo-de-precisao-em-florestas-tropicais>>.

DELEGIDO, J.; VERRELST, J.; ALONSO, L.; MORENO, J. Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. **Sensors**, v. 11, n. 7, p. 7063–7081, 2011.

DELEGIDO, J.; VERRELST, J.; MEZA, C. M.; RIVERA, J. P.; ALONSO, L.; MORENO, J. A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. **European Journal of Agronomy**, v. 46, p. 42–52, 2013.

DELEGIDO, J.; VERRELST, J.; RIVERA, J. P.; RUIZ-VERDÚ, A.; MORENO, J. Brown and green LAI mapping through spectral indices. **International Journal of Applied Earth Observation and Geoinformation**, v. 35, p. 350–358, 2015.

DOBBER, M. R.; DIRKSEN, R. J.; LEVELT, P. F.; VAN DEN OORD, G. H. J.; VOORS, R. H. M.; KLEIPOOL, Q.; JAROSS, G.; KOWALEWSKI, M.; HILSEN RATH, E.; LEPPELMEIER, G. W.; DE VRIES, J.; DIERSSEN, W.; ROZEMEIJER, N. C. Ozone monitoring instrument calibration. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 5, p. 1209–1238, 2006.

DONG, T.; MENG, J.; SHANG, J.; LIU, J.; WU, B.; HUFFMAN, T. Modified vegetation indices for estimating crop fraction of absorbed photosynthetically

active radiation. **International Journal of Remote Sensing**, v. 36, n. 12, p. 3097–3113, 2015.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G. MONTEIRO, A. V. M. (Orgs.). **Análise espacial de dados geográficos**. Planaltina: Embrapa, 2004.

DRUMOND, M. A.; KIILL, L. H. P.; NASCIMENTO, C. E. S.; BORBA, B. C. Sociabilidade das espécies arbóreas arbustivas da Caatinga em Petrolina-PE. In: CONGRESSO E EXPOSIÇÃO INTERNACIONAL SOBRE FLORESTAS. 2000, Porto Seguro. **Anais...** Porto Seguro: Instituto Ambiental Biosfera, 2000. p. 373.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote sensing of Environment**, v. 120, n. sp-1322/2, p. 25–36, maio 2012.

DUBAYAH, R.; KNOX, R.; HOFTON, M.; BLAIR, J. B.; DRAKE, J. In: HILL, M. J.; ASPINALL, R. J. (Orgs.). **Land surface characterization using lidar remote sensing**. Amsterdam: Gordon and Breach Science, 2000. p.25–38. Disponível em: <<http://www.geog.umd.edu/vcl/pubs/chapter.pdf>>. 3.

EMBRAPA. **Manual de métodos de análise de solos**. Rio de Janeiro: SNLCS, 1979.

EMBRAPA SEMIÁRIDO. **Dados meteorológicos**. Disponível em: <<http://www.cpatsa.embrapa.br:8080/index.php?op=dadosmet>>. Acesso em: 15 jan. 2017.

EMDE, C.; BURAS-SCHNELL, R.; KYLLING, A.; MAYER, B.; GASTEIGER, J.; HAMANN, U.; KYLLING, J.; RICHTER, B.; PAUSE, C.; DOWLING, T.; BUGLIARO, L. The libradtran software package for radiative transfer calculations (version 2.0.1). **Geoscientific Model Development**, v. 9, n. 5, p. 1647–1672, 2016.

EUROPEAN SPACE AGENCY. **Global monitoring for environment and security (GMES)**. Disponível em: <[http://www.esa.int/About\\_Us/Ministerial](http://www.esa.int/About_Us/Ministerial)>

\_Council\_2012/Global\_Monitoring\_for\_Environment\_and\_Security\_GMES>. Acesso em: 9 fev. 2017.

EUROPEAN SPACE AGENCY. **Multispectral instrument (MSI) overview**. Disponível em: <<https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>>. Acesso em: 7 mar. 2018.

FARIAS, S. G. G.; RODAL, M. J. N.; MELO, A. L.; SILVA, M. A. M.; LIMA, A. L. A. Fisionomia e estrutura de vegetação de Caatinga em diferentes ambientes em Serra Talhada - Pernambuco. **Ciencia Florestal**, v. 26, n. 2, p. 435–448, 2016.

FEITOZA, M. O. M. **Variação interanual do componente herbáceo em áreas de Caatinga preservada e manejada no sertão pernambucano Recife - PE**. 2013. 107p. Tese (Doutorado em Botânica) - Universidade Federal Rural de Pernambuco, Recife, 2013.

FELICIANO, E. A.; WDOWINSKI, S.; POTTS, M. D.; LEE, S. K.; FATOYINBO, T. E. Estimating mangrove canopy height and above-ground biomass in the everglades national park with airborne lidar and tandem-x data. **Remote Sensing**, v. 9, n. 7, 2017.

FERNANDES, M. R. M.; MATRICARDI, E. A. T.; ALMEIDA, A. Q.;  
FERNANDES, M. M. Mudanças do uso e de cobertura da terra na região semiárida de Sergipe. **Floresta e Ambiente**, v. 22, n. 4, p. 472–482, dez. 2015.

FERRAZ, E. M. N. GUEIRA; RODAL, M. J. N.; SAMPAIO, E. V. S. B. Physiognomy and structure of vegetation along an altitudinal gradient in the semi-arid region of northeastern Brazil. **Phytocoenologia**, v. 33, n. 1, p. 71–92, 1 abr. 2003.

FRAMPTON, W. J. J.; DASH, J.; WATMOUGH, G.; MILTON, E. J. J. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 2013.

FRANCISCO, P. R. M.; CHAVES, I. B.; LIMA, E. R. V.; BANDEIRA, M. M.;

SILVA, B. B. Mapeamento da Caatinga com uso de geotecnologia e análise da umidade antecedente em bacia hidrográfica. **Revista Brasileira de Geografia Física**, v. 3, p. 676–693, 2012.

GALINDO, I. C. L.; RIBEIRO, M. R.; SANTOS, F. A. V.; WANDERLEY, J. F.; LIMA, F.; FERREIRA, R. F. A. L. Relações solo-vegetação em áreas sob processo de desertificação no município de Jataúba, PE. **Revista Brasileira de Ciência do Solo**, v. 32, n. 1, p. 1283–1296, 2008.

GALVÍNCIO, J. D.; MOURA, M. S. B.; SILVA, T. G. F.; SILVA, B. B.; NAUE, C. R. LAI improved to dry forest in semiarid of the Brazil. **International Journal of Remote Sensing Application**, v. 3, n. 4, p. 193, 2013.

GARCIA-FECED, C.; TEMPEL, D. J.; KELLY, M. Lidar as a tool to characterize wildlife habitat: California spotted owl nesting habitat as an example. **Journal of Forestry**, p. 436–443, Dec. 2011.

GIULIETTI, A. M.; BOCAGE NETA, A. N. DU; CASTRO, A. A. J. F.; GAMARRA-ROJAS, C. F. L.; SAMPAIO, E. V. S. B.; VIRGÍNIO, J. F.; QUEIROZ, L. P.; FIGUEIREDO, M. A.; RODAL, M. J. N.; BARBOSA, M. R. DE V.; HARLEY, R. M.; SILVA, J. M. C. DA; TABARELLI, M.; FONSECA, M. T.; LINS, L. V. (Orgs.). **Diagnóstico da vegetação nativa do bioma Caatinga**. Brasília: Ministério do Meio Ambiente, 2004. 382 p. Disponível em: <[http://ainfo.cnptia.embrapa.br/digital/bitstream/item/18267/1/Biodiversidad e\\_Caatinga\\_parte2.pdf](http://ainfo.cnptia.embrapa.br/digital/bitstream/item/18267/1/Biodiversidad_e_Caatinga_parte2.pdf)>.

GOETZ, S.; STEINBERG, D.; DUBAYAH, R.; BLAIR, B. Laser remote sensing of canopy habitat heterogeneity as a predictor of bird species richness in an eastern temperate forest, USA. **Remote Sensing of Environment**, v. 108, n. 3, p. 254–263, 2007.

GRATANI, L.; VARONE, L.; RICOTTA, C.; CATONI, R. Mediterranean shrublands carbon sequestration: environmental and economic benefits. **Mitigation and Adaptation Strategies for Global Change**, v. 18, n. 8, p. 1167–1182, 2013.

GREGO, C. R.; VIEIRA, S. R. Variabilidade espacial de propriedades físicas do solo em uma parcela experimental. **Revista Brasileira de Ciência do Solo**, v. 29, n. 2, p. 169–177, 2005.

GUEDES FILHO, O.; VIEIRA, S. R.; CHIBA, M. K.; NAGUMO, C. H.; DECHEN, S. C. F. Spatial and temporal variability of crop yield and some rhodic hapludox properties under no-tillage. **Revista Brasileira de Ciência do Solo**, v. 34, n. 1, p. 1–14, fev. 2010.

HA, H.; OLSON, J. R.; BIAN, L.; ROGERSON, P. A. Analysis of heavy metal sources in soil using kriging interpolation on principal components.

**Environmental Science and Technology**, v. 48, n. 9, p. 4999–5007, 2014.

HARDING, D. J.; LEFSKY, M. A.; PARKER, G. G.; BLAIR, J. B. Laser altimeter canopy height profiles methods and validation for closed-canopy, broadleaf forests. **Remote sensing of Environment**, v. 76, n. 3, p. 283–297, 2001.

HARDISKY, M. A.; KLEMAS, V.; SMART, R. M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of spartina alterniflora canopies. **Photogrammetric Engineering and Remote Sensing**, v. 49, n. 1, p. 77–83, 1983.

HÄRDLE, W.; SIMAR, L. **Applied multivariate statistical analysis**. Berlim: Pearson, 2003. v. 47.

HEUNG, B.; HO, H. C.; ZHANG, J.; KNUDBY, A.; BULMER, C. E.; SCHMIDT, M. G. An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. **Geoderma**, v. 265, p. 62–77, 2016.

HICKEY, S. M.; CALLOW, N. J.; PHINN, S.; LOVELOCK, C. E.; DUARTE, C. M. Spatial complexities in aboveground carbon stocks of a semi-arid mangrove community: a remote sensing height-biomass-carbon approach. **Estuarine, Coastal and Shelf Science**, v. 200, p. 194–201, 2018.

HMIDA, S. BEN; KALLEL, A.; GASTELLU-ETCHEGORRY, J. P.; ROUJEAN, J. L. Crop biophysical properties estimation based on lidar full-waveform inversion

- using the data from. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 11, p. 4853–4868, 2017.
- HODGSON, M. E. What size window for image classification? a cognitive perspective. **Photogrammetric Engineering & Remote Sensing**, v. 64, n. 8, p. 797–807, 1998.
- HUETE, A. R.; JUSTICE, C. MODIS vegetation index algorithm theoretical basis. **Environmental Sciences**, n. 13, p. 129, 1999.
- HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; J., L. VAN W. A comparison of vegetation indices over a global set of TM images for EO-MODIS. **Remote Sensing of Environment**, v. 59, p. 440–451, 1997.
- HÜTTICH, C.; HEROLD, M.; WEGMANN, M.; CORD, A.; STROHBACH, B.; SCHMULLIUS, C.; DECH, S. Assessing effects of temporal compositing and varying observation periods for large-area land-cover mapping in semi-arid ecosystems: implications for global monitoring. **Remote Sensing of Environment**, v. 115, n. 10, p. 2445–2459, 2011.
- INTERNATIONAL BUSINESS MACHINE - IBM. **IBM SPSS statistics base 22**. 2013. Disponível em: <[http://www.cc.uoa.gr/fileadmin/cc.uoa.gr/uploads/files/manuals/SPSS22/IBM\\_SPSS\\_Statistics\\_Base.pdf](http://www.cc.uoa.gr/fileadmin/cc.uoa.gr/uploads/files/manuals/SPSS22/IBM_SPSS_Statistics_Base.pdf)>.
- JACKSON, J. E. **A user's guide to principal components**. Hoboken: John Wiley & Sons, 2004.
- JACOMINE, P. K. T.; ALMEIDA, J. C.; MEDEIROS, L. A. R. Levantamento exploratório - reconhecimento de solos do estado do Ceará. **Boletim Técnico**, v. 28, p. 455, 1973.
- JACOMINE, P. K. T.; CAVALCANTI, A. C.; BURGOS, N.; PESSOA, S. C. P.; SILVEIRA, C. O. Levantamento exploratório - reconhecimento de solos do estado de Pernambuco. **Boletim Técnico**, v. 26, n. 1, 1973.
- JACOMINE, P. K. T.; CAVALCANTI, A. C.; BURGOS, N.; SILVA, F. B. R. E.;



LOPES, O. F. Levantamento exploratorio-reconhecimento de solos da margem direita do rio Sao Francisco estado da Bahia. **Boletim Técnico**, v. 52, n. 1, p. 735, 1977.

JACOMINE, P. K. T.; CAVALCANTI, A. C.; FORMIGA, R. A.; SILVA, F. B. R. E.; BURGOS, N.; MEDEIROS, L. A. R.; LOPES, O. F.; MELO FILHO, H. F. R. DE; PESSOA, S. C. P.; LIMA, P. C. Levantamento exploratório de reconhecimento de solos do norte de Minas Gerais. **Boletim Técnico**, v. 60, n. 12, p. 426, 1979.

JACOMINE, P. K. T.; CAVALCANTI, A. C.; PESSOA, S. C. P.; BURGOS, N.; FILHO, H. F. R. M.; LOPES, O. F.; MEDEIROS, L. A. R.; FORMIGA, R. A. Levantamento exploratório - reconhecimento de solos do estado do Piauí. **Boletim de Pesquisa**, v. 36, p. 557, 1986.

JACOMINE, P. K. T.; CAVALCANTI, A. C.; RIBEIRO, M. R.; MONTENEGRO, J. O.; BURGOS, N.; MÉLO FILHO, H. F. R. DE. Levantamento exploratório de reconhecimento de solos da margem esquerda do rio São Francisco - estado da Bahia. **Boletim Técnico**, v. 38, n. 7, p. 439, 1976.

JACOMINE, P. K. T.; MONTENEGRO, J. O.; RIBEIRO, M. R.; FORMIGA, R. A. Levantamento exploratório de reconhecimento de solos do estado de Sergipe. **Boletim Técnico**, v. 36, n. 6, p. 544, 1975.

JACOMINE, P. K. T.; RIBEIRO, M. R.; MONTENEGRO, J. C.; SILVA, A. P.; MELO FILHO, H. F. R. Levantamento exploratorio reconhecimento de solos do estado da Paraiba. **Boletim de Pesquisa**, v. 15, p. 683, 1972.

JACOMINE, P. K. T.; SILVA, F. B. R. ; FORMIGA, R. A.; ALMEIDA, J. C.; BELTRÃO, V. A.; PESSOA, S. C. P.; FERREIRA, R. C. Levantamento exploratório de reconhecimento de solos do estado do Rio Grande do Norte. **Boletim Técnico**, v. 21, n. p, p. 536, 1971.

JACON, A. D.; GALVÃO, L. S.; SANTOS, J. R.; SANO, E. E. Seasonal characterization and discrimination of savannah physiognomies in Brazil using hyperspectral metrics from hyperion/eo-1. **International Journal of Remote**

**Sensing**, v. 38, n. 15, p. 4494–4516, 2017.

JAVZANDULAM, T.; TATEISHI, R.; SANJAA, T. Analysis of vegetation indices for monitoring vegetation degradation in semi-arid and arid areas of Mongolia.

**International Journal of Environmental Studies**, v. 62, n. 2, p. 215–225, 2005.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 6. ed. Upper Saddle River: Pearson, 2007.

JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663–666, July 1969.

KAISER, H. F. A second generation little jiffy. **Psychometrika**, v. 35, n. 4, p. 401–415, dez. 1970.

KAISER, H. F.; RICE, J. Little jiffy, mark IV. **Educational and Psychological Measurement**, v. 34, n. 1, p. 111–117, 2 abr. 1974.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261–270, 1992.

KIMES, D. S.; MARKHAM, B. L.; TUCKER, C. J.; MCMURTREY, J. E. Temporal relationships between spectral response and agronomic variables of a corn canopy. **Remote Sensing of Environment**, v. 11, n. C, p. 401–411, 1981.

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

LEFSKY, M. A.; COHEN, W. B.; PARKER, G. G.; HARDING, D. J. Lidar remote sensing for ecosystem studies. **Bioscience**, v. 52, n. 1, p. 19–30, 2002.

LEICA. **Leica ADS80**. Heerbrugg: Leica, 2011.

LEICA. **Leica ALS60**. Heerbrugg: Leica, 2008.

- LEVELT, P. F.; NOORDHOEK, R. **OMI algorithm theoretical basis document**. Ga de Bilt: KNMI, 2002. 50p.
- LIMA, A. L. A. L. A.; RODAL, M. J. N. Phenology and wood density of plants growing in the semi-arid region of northeastern Brazil. **Journal of Arid Environments**, v. 74, n. 11, p. 1363–1373, nov. 2010.
- LIMA JUNIOR, C.; ACCIOLY, L. J. O.; GIONGO, V.; LIMA, R. L. F. A.; SAMPAIO, E. V. D. S. B.; MENEZES, R. S. C. Estimativa de biomassa lenhosa da Caatinga com uso de equações alométricas e índice de vegetação. **Scientia Forestalis**, v. 42, n. 102, p. 289–298, 2014.
- LOPES, H. L.; ACCIOLY, L. J. O.; SILVA, F. H. B. B.; SOBRAL, M. C. M.; ARAÚJO FILHO, J. C.; CANDEIAS, A. L. B. Espacialização da umidade do solo por meio da temperatura da superfície e índice de vegetação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 9, p. 973–980, set. 2011.
- LOPES, H. L.; CABRAL, J. J. D. S. P.; ARAÚJO FILHO, J. C.; MONTENEGRO, S. M. G. L. Mapeamento de áreas aluvionares no semiárido brasileiro por meio de dados colaterais e imagens orbitais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, n. 81, p. 763–769, 2013.
- LOUIS, J.; DEBAECKER, V.; PFLUG, B.; MAIN-KNORN, M.; BIENIARZ, J.; MUELLER-WILM, U.; CADAU, E.; GASCON, F. **Sentinel-2 sen2cor: I2a processor for users**. Paris: European Space Agency, 2016.
- MALDONADO, F. D.; SANTOS, J. R.; CARVALHO, V. C. Land use dynamics in the semi-arid region of Brazil (Quixaba, PE): characterization by principal component analysis (PCA). **International Journal of Remote Sensing**, v. 23, n. 23, p. 5005–5013, 2002.
- MEDEIROS, S. S.; CAVALCANTE, A. M. B.; MARIN, A. M. P.; TINÔCO, L. B. M.; SALCEDO, I. H.; PINTO, T. F. **Sinópsese do censo demográfico para o semiárido brasileiro**. Campina Grande: INSA, 2012.
- MEDINA, H.; JONG VAN LIER, Q.; GARCÍA, J.; RUIZ, M. E. Regional-scale

variability of soil properties in western Cuba. **Soil and Tillage Research**, v. 166, p. 84–99, mar. 2017.

MEIRELLES, M. S. P.; CAMARA, G.; ALMEIDA, C. M. (Orgs.). **Geomática**. Brasília: Embrapa, 2007.

MELO, E. T.; SALES, M. C. L.; OLIVEIRA, J. G. B. Aplicação do índice de vegetação por diferença normalizada (NDVI) para análise da degradação ambiental da microbacia hidrográfica do riacho dos Cavalos, Crateús-CE.

**Raega - O Espaço Geográfico em Análise**, v. 23, p. 520–533, 2011.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem prática**. Belo Horizonte: Editora UFMG, 2005.

MOORE, C. E.; BROWN, T.; KEENAN, T. F.; DUURSMA, R. A.; VAN DIJK, A. I. J. M.; BERINGER, J.; CULVENOR, D.; EVANS, B.; HUETE, A. R.; HUTLEY, L. B.; MAIER, S.; RESTREPO-COUBE, N.; SONNENTAG, O.; SPECHT, A.; TAYLOR, J. R.; VAN GORSEL, E.; LIDDELL, M. J. Reviews and syntheses: australian vegetation phenology: new insights from satellite remote sensing and digital repeat photography. **Biogeosciences**, v. 13, n. 17, p. 5085–5102, 2016.

MOREIRA, L. C. J.; DURAND, B. J.; TEIXEIRA, A. S.; ANDRADE, E. M. Variabilidade local e regional da evapotranspiração estimada pelo algoritmo sebal. **Engenharia Agrícola**, v. 30, n. 6, p. 1148–1159, 2010.

MOREIRA, L. C. J.; TEIXEIRA, A. D. S.; GALVÃO, L. S. Potential of multispectral and hyperspectral data to detect saline-exposed soils in Brazil. **Giscience & Remote Sensing**, v. 52, n. 4, p. 416–436, 2015.

MORO, M. F.; NIC LUGHADHA, E.; FILER, D. L.; ARAÚJO, F. S. DE; MARTINS, F. R. A catalogue of the vascular plants of the Caatinga hytogeographical domain: a synthesis of floristic and phytosociological surveys. **Phytotaxa**, v. 160, n. 1, p. 1, 19 fev. 2014.

MORO, M. F.; SILVA, I. A.; ARAÚJO, F. S.; LUGHADHA, E. N.; MEAGHER, T. R.; MARTINS, F. R. The role of edaphic environment and climate in structuring phylogenetic pattern in seasonally dry tropical plant communities. **Plos One**, v.

10, n. 3, p. 1–18, 2015.

MOTTA, J. D.; CANDEIAS, A. L. B.; GONZAGA, E. N. Extração de solo exposto e inferência do tipo de solo a partir do estudo da drenagem usando-se técnicas de sensoriamento remoto e geoprocessamento. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 1, n. 1, p. 29–34, 1997.

MOURA, Y. M.; GALVÃO, L. S.; HILKER, T.; WU, J.; SALESKA, S.; AMARAL, C. H.; NELSON, B. W.; LOPES, A. P.; WIEDEMAN, K. K.; PROHASKA, N.; OLIVEIRA, R. C.; MACHADO, C. B.; ARAGÃO, L. E. O. C. Spectral analysis of amazon canopy phenology during the dry season using a tower hyperspectral camera and MODIS observations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 52–64, 2017.

MUELLER-WILM, U.; DEVIGNO, O.; PESSIOT, L. **S2 MPC L2A Product Definition Document**. Paria: ESA, 2015. 35p.

MÜLLER, H.; RUFIN, P.; GRIFFITHS, P.; BARROS SIQUEIRA, A. J.; HOSTERT, P. Mining dense landsat time series for separating cropland and pasture in a heterogeneous brazilian savanna landscape. **Remote Sensing of Environment**, v. 156, p. 490–499, 2015.

MUNDT, J. T.; STREUTKER, D. R.; GLENN, N. F. Mapping sagebrush distribution using fusion of hyperspectral and lidar classifications. **Photogrammetric Engineering Remote Sensing**, v. 72, n. 1, p. 47–54, 2006.

NIÑEROLA, V. B.; NAVARRO-PEDREÑO, J.; LUCAS, I. G.; PASTOR, I. M.; VIDAL, M. M. J. Geostatistical assessment of soil salinity and cropping systems used as soil phytoremediation strategy. **Journal of Geochemical Exploration**, v. 174, p. 53–58, mar. 2017.

OLIVEIRA, S. N.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T.; GUIMARÃES, R. F.; MCMANUS, C. M. Deforestation analysis in protected areas and scenario simulation for structural corridors in the agricultural frontier of western Bahia, Brazil. **Land Use Policy**, v. 61, p. 40–52, fev. 2017.

OMASA, K.; HOSOI, F.; KONISHI, A. 3D lidar imaging for detecting and

understanding plant responses and canopy structure. **Journal of Experimental Botany**, v. 58, n. 4, p. 881–898, 2007.

OMASA, K.; HOSOI, F.; UENISHI, T. M.; SHIMIZU, Y.; AKIYAMA, Y. Three-dimensional modeling of an urban park and trees by combined airborne and portable on-ground scanning lidar remote sensing. **Environmental Modeling and Assessment**, v. 13, n. 4, p. 473–481, 2008.

PARADELLA, W. R.; VITORELLO, I. Geobotanical and soil spectral investigation for rock discrimination in the “Caatinga” environment (Brazil) based on multitemporal remote sensing data. **Canadian Journal of Remote Sensing**, v. 21, n. 1, p. 52–59, 1995.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, É. Scikit-learn: machine learning in python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2012.

PESSOA, L. G. M.; FREIRE, M. B. G. D. S.; WILCOX, B. P.; GREEN, C. H. M.; ARAÚJO, R. J. T.; ARAÚJO FILHO, J. C. Spectral reflectance characteristics of soils in northeastern Brazil as influenced by salinity levels. **Environmental Monitoring and Assessment**, v. 188, n. 11, p. 616, 2016.

PETTA, R. A.; CARVALHO, L. V.; ERASMI, S.; JONES, C. Evaluation of desertification processes in Seridó region (NE Brazil). **International Journal of Geosciences**, v. 4, n. 5, p. 12–17, 2013.

PINHEIRO, E. A. R.; COSTA, C. A. G.; ARAÚJO, J. C. Effective root depth of the Caatinga biome. **Journal of Arid Environments**, v. 89, p. 1–4, 2013.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. 2. ed. São José dos Campos: Parêntese, 2009.

RAMOELO, A.; CHO, M.; MATHIEU, R.; SKIDMORE, A. K. Potential of Sentinel-2 spectral configuration to assess rangeland quality. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 94096, 2015.

- RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma cerrado. In: SANO, S. M.; ALMEIDA, S. P. (Orgs.). **Cerrado: ambiente e flora**. Planaltina: Embrapa Cerrados, 1998.
- ROBERTS, D. A.; SMITH, M. O.; ADAMS, J. B. Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. **Remote Sensing of Environment**, v. 44, n. 2–3, p. 255–269, 1993.
- ROCHA NETO, O.; TEIXEIRA, A.; LEÃO, R.; MOREIRA, L.; GALVÃO, L. Hyperspectral remote sensing for detecting soil salinization using ProSpecTIR-VS aerial imagery and sensor simulation. **Remote Sensing**, v. 9, n. 1, p. 42, 2017.
- RODAL, M. J. N.; COSTA, K. C. C.; SILVA, A. C. B. L. E. Estrutura da vegetação caducifólia espinhosa (Caatinga) de uma área do sertão central de Pernambuco. **Hoehnea**, v. 35, n. 2, p. 209–217, 2008.
- RODAL, M. J. N.; MARTINS, F. R.; SAMPAIO, E. V. S. B. Levantamento quantitativo das plantas lenhosas em trechos de vegetação de Caatinga em Pernambuco. **Revista Caatinga**, v. 21, n. 3, p. 15, 2008.
- RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, n. 1, p. 93–104, 2012.
- RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, p. 95–107, 1996.
- ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE (ERTS) SYMPOSIUM, 3., 1973, . **Proceedings...** [S.l: s.n.], 1973. p. 309–317.
- SÁ, I. B. Mesa redonda nº 34: classificação da vegetação brasileira. In: CONGRESSO NACIONAL DE BOTÂNICA, 59., 2008, Natal. **Anais...** Natal: Sociedade Botânica do Brasil, 2008.

SÁ, I. B.; CUNHA, T. J. F.; TAURA, T. A.; DRUMOND, M. A. Mapeamento da desertificação da mesorregião sul do ceará com base na cobertura vegetal e nas classes de solos. **Revista Brasileira de Geografia Física**, v. 7, p. 572–583, 2014.

SÁ, I. B.; CUNHA, T. J.; TAURA, T. A.; DRUMOND, M. A. Mapeamento da desertificação da região de desenvolvimento sertão do São Francisco com base na cobertura vegetal e nas classes de solos. **Revista Brasileira de Geografia Física**, v. 8, p. 510–524, 2015.

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

SAMPAIO, E.; RODAL, M. J. N. **Avaliação e identificação de ações prioritárias para a conservação, utilização sustentável e repartição de benefícios da biodiversidade do bioma Caatinga**. Petrolina: Embrapa, 2000. 14p.

SANTOS, M. F.; RIBEIRO, M. R.; SAMPAIO, E. V. S. B. Semelhanças vegetacionais em sete solos da Caatinga. **Pesquisa Agropecuária Brasileira**, v. 27, 1992.

SCHLEMMER, M.; GITELSON, A. A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, n. 1, p. 47–54, 2013.

SCHULZ, C.; KOCH, R.; CIERJACKS, A.; KLEINSCHMIT, B. Land change and loss of landscape diversity at the Caatinga phytogeographical domain – analysis of pattern-process relationships with MODIS land cover products (2001–2012). **Journal of Arid Environments**, v. 136, p. 54–74, 2017.

SECRETARIA DE DESENVOLVIMENTO ECONÔMICO. **Pernambuco tridimensional**. Disponível em: <<http://www.pe3d.pe.gov.br/>>. Acesso em: 23 maio 2017.



- SENA, M.; FRIGHETTO, R. T.; VALARINI, P.; TOKESHI, H.; POPPI, R. Discrimination of management effects on soil parameters by using principal component analysis: a multivariate analysis case study. **Soil and Tillage Research**, v. 67, n. 2, p. 171–181, 2002.
- SHEPARD, C.; SCHAAP, M. G.; CRIMMINS, M. A.; VAN LEEUWEN, W. J. D.; RASMUSSEN, C. Subsurface soil textural control of aboveground productivity in the us desert southwest. **Geoderma Regional**, v. 4, p. 44–54, 2015.
- SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 110, p. 55–65, 2015.
- SILVA, C. A.; HUDAK, A. T.; KLAUBERG, C.; VIERLING, L. A.; GONZALEZ-BENECKE, C.; PADUA CHAVES CARVALHO, S.; RODRIGUEZ, L. C. E.; CARDIL, A. Combined effect of pulse density and grid cell size on predicting and mapping aboveground carbon in fast-growing eucalyptus forest plantation using airborne lidar data. **Carbon Balance and Management**, v. 12, n. 1, p. 1–16, 2017.
- SILVA, E. A.; FERREIRA, R. L. C.; SILVA, J. A. A.; SÁ, I. B.; DUARTE, S. M. A. Dinâmica do uso e cobertura da terra do município de Floresta, PE, **Floresta**, Curitiba: UFPR v. 43, n. 4, p. 611–620, 2013.
- SILVA, F. B. R. E.; RICHE, G. R.; TONNEAU, J. P.; SOUZA NETO, N. C. DE; BRITO, L. T. L.; CORREIA, R. C.; CAVALCANTI, A. C.; SILVA, F. H. B. B. DA; SILVA, A. B. DA; ARAUJO FILHO, J. C. D.; LEITE, A. P. Zoneamento agroecológico do nordeste: diagnóstico do quadro natural e agrossocioeconômico. **Documentos**, v. 80, 1993.
- SILVA, A. P. N.; MOURA, G. B. D. A.; GIONGO, P. R.; SILVA, A. O. Dinâmica espaço-temporal da vegetação no semi-árido de Pernambuco. **Revista Caatinga**, v. 22, n. 4, p. 195–205, 2009.
- SILVA, B. B.; BRAGA, A. C.; BRAGA, C. C.; OLIVEIRA, L. M. M.; GALVÍNCIO,

J. D.; MONTENEGRO, S. M. G. L. Evapotranspiração e estimativa da água consumida em perímetro irrigado do semiárido brasileiro por sensoriamento remoto. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1218–1226, set. 2012.

SILVA, B. B.; BRAGA, A. C.; BRAGA, C. C.; OLIVEIRA, L. M. M.; MONTENEGRO, S. M. G. L.; BARBOSA JUNIOR, B. Procedures for calculation of the albedo with OLI-Landsat 8 images: application to the brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 1, p. 3–8, 2016.

SILVA, B. B.; LOPES, G. M.; AZEVEDO, P. V. Balanço de radiação em áreas irrigadas utilizando imagens Landsat 5-TM. **Revista Brasileira de Meteorologia**, v. 20, n. 2, p. 243–252, 2005.

SILVA, B. B.; LOPES, G. M.; AZEVEDO, P. V. Determinação do albedo de áreas irrigadas com base em imagens Landsat 5-TM. **Revista Brasileira de Agrometeorologia**, p. 11–21, 2005.

SILVA, F. F.; SANTOS, J. R. Imagens ALOS/PALSAR na classificação da cobertura vegetal da região semi-árida brasileira. **Revista Brasileira de Cartografia**, v. 63, p. 75–83, 2011.

SILVA, K. A.; ARAÚJO, E. D. L.; FERRAZ, E. M. N. Estudo florístico do componente herbáceo e relação com solos em áreas de Caatinga do embasamento cristalino e bacia sedimentar, Petrolândia, PE, Brasil. **Acta Botanica Brasilica**, v. 23, n. 1, p. 100–110, 2009.

SILVA, P. F.; LIMA, J. R. S.; ANTONINO, A. C. D.; SOUZA, R.; SOUZA, E. S.; SILVA, J. R. I.; ALVES, E. M. Seasonal patterns of carbon dioxide, water and energy fluxes over the Caatinga and grassland in the semi-arid region of Brazil. **Journal of Arid Environments**, v. 147, p. 71–82, 2017.

SILVEIRA, H. L. F.; EBERHARDT, I. D. R.; SANCHES, I. D.; GALVÃO, L. S.; Análise da cobertura de nuvens no nordeste do Brasil e seus impactos no sensoriamento remoto agrícola operacional . In: SIMPÓSIO BRASILEIRO DE

- SENSORIAMENTO REMOTO, 23., 2017, Santos. **Anais...** São José dos Campos: INPE, 2017. p. 400–407.
- SOUZA, L. S. B.; MOURA, M. S. B.; SEDIYAMA, G. C.; SILVA, T. G. F. Balanço de radiação em ecossistema de Caatinga preservada durante um ano de seca no semiárido pernambucano. **Revista Brasileira de Geografia Física**, v. 8, n. 1, p. 41–55, 2015.
- TAVARES, M. T.; SOUSA, A. J.; ABREU, M. M. Ordinary kriging and indicator kriging in the cartography of trace elements contamination in São Domingos mining site (Alentejo, Portugal). **Journal of Geochemical Exploration**, v. 98, n. 1–2, p. 43–56, 2008.
- TEIXEIRA, A. H. C.; LEIVASA, J. F.; ANDRADEA, R. G.; HERNANDEZB, F. B. T.; MOMESSO, F. R. A. Modelling radiation and energy balances with Landsat 8 images under different thermohydrological conditions in the brazilian semi-arid region. In: REMOTE SENSING FOR AGRICULTURE, ECOSYSTEMS, AND HYDROLOGY, 17., 2015, Toulouse. **Proceedings...** Toulouse: SPIE, 2015. p. 96370U.
- THENKABAIL, P. S.; LYON, J. G.; HUETE, A. R. (Orgs.). **Hyperspectral remote sensing of vegetation**. Boca Raton: CRC Press, 2012.
- TONGWAY, D. J.; LUDWIG, J. A. Vegetation and soil patterning in semi-arid mulga lands of eastern Australia. **Australian Journal of Ecology**, v. 15, n. 1, p. 23–34, 1990.
- TONIOL, A. C.; GALVÃO, L. S.; PONZONI, F. J.; SANO, E. E.; DE JESUS AMORE, D. Potential of hyperspectral metrics and classifiers for mapping brazilian savannas in the rainy and dry seasons. **Remote Sensing Applications: Society and Environment**, v. 8, p. 20–29, 2017.
- VASQUES, G. M.; COELHO, M. R.; DART, R. O.; OLIVEIRA, R. P.; TEIXEIRA, W. G. Mapping soil carbon, particle-size fractions, and water retention in tropical dry forest in Brazil. **Pesquisa Agropecuaria Brasileira**, v. 51, n. 9, p. 1371–1385, 2016.

VIEIRA, R. M. S. P.; TOMASELLA, J.; ALVALÁ, R. C. S.; SESTINI, M. F.; AFFONSO, A. G.; RODRIGUEZ, D. A.; BARBOSA, A. A.; CUNHA, A. P. M. A.; VALLES, G. F.; CREPANI, E.; OLIVEIRA, S. B. P.; SOUZA, M. S. B.; CALIL, P. M.; CARVALHO, M. A.; VALERIANO, D. M.; CAMPELLO, F. C. B.; SANTANA, M. O. Identifying areas susceptible to desertification in the brazilian northeast. **Solid Earth**, v. 6, n. 1, p. 347–360, 2015.

VIEIRA, S. R.; DECHEN, S. C. F.; SIQUEIRA, G. M.; DUFRANC, G. Variabilidade espacial de atributos físicos e químicos relacionados com o estado de agregação de dois latossolos cultivados no sistema de semeadura direta. **Bragantia**, v. 70, n. 1, p. 185–195, 2011.

VIERLING, L. A.; XU, Y.; EITEL, J. U. H.; OLDOW, J. S. Shrub characterization using terrestrial laser scanning and implications for airborne lidar assessment. **Canadian Journal of Remote Sensing**, v. 38, n. 6, p. 709–722, 2012.

VISCARRA ROSSEL, R. A.; MCBRATNEY, A. B.; MINASNY, B. **Proximal soil sensing**. Londres: Springer, 2011.

WASKE, B.; FAUVEL, M.; BENEDIKTSSON, J. A.; CHANUSSOT, J. Machine learning techniques in remote sensing data analysis. In: CAMPS-VALLS, G.; BRUZZONE, L. (Orgs.). **Kernel methods for remote sensing data analysis**. New York: : John Wiley & Sons, 2009. p.1-24.

WORLD METEOROLOGICAL ORGANIZATION. **Statement on the status of the global climate in 2013**. Genebra: WMO, 2014. Disponível em: <[http://www.wmo.int/pages/mediacentre/press\\_releases/documents/WMO\\_1108\\_EN\\_web\\_000.pdf](http://www.wmo.int/pages/mediacentre/press_releases/documents/WMO_1108_EN_web_000.pdf)>.

WU, C.; NIU, Z.; TANG, Q.; HUANG, W. Estimating chlorophyll content from hyperspectral vegetation indices: modeling and validation. **Agricultural and Forest Meteorology**, v. 148, n. 8–9, p. 1230–1241, 2008.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de textos, 2013.