



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS AGRÁRIAS**  
**DEPARTAMENTO DE ZOOTECNIA**  
**PROGRAMA PÓS-GRADUAÇÃO EM ZOOTECNIA**

**LEONARDO FIUSA DE MORAIS**

**TÉCNICAS DE MODELAGEM E GEOPROCESSAMENTO VISANDO AO  
DESENVOLVIMENTO DE UM SISTEMA DE ALERTA PRECOCE PARA OS  
REBANHOS EM REGIÕES DA CAATINGA**

**FORTALEZA**

**2021**

LEONARDO FIUSA DE MORAIS

TÉCNICAS DE MODELAGEM E GEOPROCESSAMENTO VISANDO AO  
DESENVOLVIMENTO DE UM SISTEMA DE ALERTA PRECOCE PARA OS  
REBANHOS EM REGIÕES DA CAATINGA

Tese apresentada ao Programa pós-graduação  
em Zootecnia da Universidade Federal do  
Ceará como requisito parcial para obtenção de  
título de Doutor em Zootecnia. Área de  
Concentração: Forragicultura

Orientador: Prof. Dr. Magno José Duarte  
Cândido

Coorientador: Dra. Ana Clara Rodrigues  
Cavalcante

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- M825      Morais, Leonardo Fiusa de.  
            Técnicas de modelagem e geoprocessamento visando ao desenvolvimento de um sistema de alerta precoce para os rebanhos em regiões da Caatinga / Leonardo Fiusa de Morais. – 2021.  
            109 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Zootecnia, Fortaleza, 2021.  
            Orientação: Prof. Dr. Magno José Duarte Cândido.
1. Ajuste de taxa de lotação. 2. Análise pecuária. 3. Classificação de imagens. 4. Índices espectrais de vegetação. 5. Google earth engine. I. Título.

CDD 636.08

---

LEONARDO FIUSA DE MORAIS

TÉCNICAS DE MODELAGEM E GEOPROCESSAMENTO VISANDO AO  
DESENVOLVIMENTO DE UM SISTEMA DE ALERTA PRECOCE PARA OS  
REBANHOS EM REGIÕES DA CAATINGA

Tese apresentada ao Programa pós-graduação  
em Zootecnia da Universidade Federal do  
Ceará como requisito parcial para obtenção de  
título de Doutor em Zootecnia. Área de  
Concentração: Forragicultura

Aprovada em \_\_/\_\_/\_\_.

BANCA EXAMINADORA

---

Prof. Dr. Magno José Duarte Cândido  
Universidade Federal do Ceará (UFC)

---

Dr. Deodato do Nascimento Aquino  
Instituto Nacional de Colonização e Reforma Agrária (INCRA)

---

Prof. Dr. Rodrigo Gregório da Silva  
Instituto Federal de Educação (IFCE)

---

Dr. Cristiam Bosi  
Empresa Brasileira de Pesquisa Agropecuária (Embrapa)

---

Prof. Dr. Valdson José da Silva  
Universidade Federal Rural do Pernambuco (UFRPE)

Aos meus Pais, Zacarias Feitosa de Moraes e  
Ana Sátiro Fiusa de Moraes pelo apoio e  
carinho.

A vocês dedico este trabalho.

## AGRADECIMENTOS

Em agosto de 2016, quando iniciei o doutorado no PDIZ, jamais podia imaginar que o final coincidiria com um momento tão delicado e de tanto desgaste emocional em função de um problema de saúde pública mundial. Portanto, primeiramente, quero agradecer a Deus por ter me protegido e ter me fornecido o mínimo de paz e tranquilidade necessária para finalizar este trabalho, bem como por preservar a vida e a saúde de muitas pessoas boas que conheço.

Também preciso agradecer ao meu pai, Zacarias Feitosa de Moraes, e minha mãe, Ana Sátiro Fiusa de Moraes, que me proporcionaram educação e ensinamentos de vida, que me tornaram uma pessoa capaz de escolher o melhor caminho a ser tomado. A educação que recebi deles foi muito importante para que eu estivesse aqui hoje.

Aos meus irmãos Marcos Fiusa e Rafael Fiusa, pela amizade e pelo apoio. A Rafael, principalmente, por ter me incentivado a encarar as dificuldades da vida acadêmica como discente de pós-graduação com responsabilidade e competência.

À minha avó Raimunda de Moraes (*in memoriam*), por ter sido uma guerreira e sempre ter orado a Deus pela minha saúde.

Às minhas primas Dinha Moraes, Meire Moraes e Flavia Machado, por todo o acolhimento e amizade durante minha estadia em Fortaleza.

Ao meu orientador professor Dr. Magno José Duarte Cândido, pelos ensinamentos e por toda confiança depositada sobre mim.

Aos coorientadores Dr. Carlos Alexandre e Dra. Ana Clara, pelos ensinamentos, pela atenção e pela valiosa contribuição na realização do projeto.

Ao Dr. Deodato Aquino, por todos os ensinamentos e pela pronta disponibilidade em ajudar na condução da pesquisa.

À Ellen Gomes, pelas contribuições com opiniões sobre o projeto, bem como as ajudas nas etapas de coleta de dados.

À Universidade Federal do Ceará, especialmente ao Departamento de Zootecnia onde está situado o programa de doutorado Integrado em Zootecnia (PDIZ), pela oportunidade de realizar o curso de doutorado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Capes, pela bolsa de estudo concedida e pelo financiamento do projeto pesquisa.

A todos os integrantes do Núcleo de Ensino e Estudos em Forragicultura (NEEF), onde fiz grandes amizades e adquiri muito conhecimento.

Aos amigos Felipe Hermínio e Breno Moreira, pela ajuda nas atividades de execução do projeto.

Aos amigos Clemente Fernandes, Jefte Arnon, Vitor Macedo, Clésio Santos, Samuel Maranhão, Bruno Bezerra, Abner Girão, Marcos Neves e Rafael Furtado agradeço pela amizade verdadeira, momentos de descontração e companheirismo, pois nunca mediram esforços para me ajudar e serão sempre considerados membros da minha família.

Ao Instituto Federal de Educação Ciência e Tecnologia do Ceará Campus Tauá, em nome dos professores Weberte Sombra e Kelvia Castro, por disponibilizar o laboratório do Instituto como apoio à execução do projeto.

Aos professores Marcos e Luzia Neuma da Escola Francisca Cavalcante Fialho, pela disponibilidade em ajudar, e pela disponibilidade do agricultor Senhor Pedro, por contribuir nas colheitas de campo. À Associação Caatinga em Ouricuri, especialmente à Henrique e Geovane, por terem sempre me recebido muito bem.

À Embrapa Caprinos e Ovinos, pelo apoio à realização da pesquisa.

Ao Prof. Dr. Jay Peter Angerer, por ter sido muito acessível em retirar dúvidas com relação ao funcionamento da plataforma PHYWEB, sendo seus conselhos e esclarecimentos decisivos para toda a execução do projeto.

A todos que, de forma direta ou indireta, contribuíram para o fim dessa empreitada!

Depois voltei-me, e atentei para todas as opressões que se fazem debaixo do sol; e eis que vi as lágrimas dos que foram oprimidos e dos que não têm consolador, e a força estava do lado dos seus opressores; mas eles não tinham consolador. Por isso eu louvei os que já morreram, mais do que os que vivem ainda (Eclesiastes 4:1-2).



## RESUMO

O objetivo deste estudo foi analisar a capacidade de técnicas de modelagem e de geoprocessamento na geração de um protocolo com informações de alerta precoce aos pecuaristas residentes em regiões do bioma Caatinga. O primeiro capítulo realizou uma análise temporal das secas e da distribuição espacial dos rebanhos do Semiárido brasileiro por ferramentas de geoprocessamento. Foram criados mapas anuais de índice de vegetação pela diferença normalizada (NDVI) e de índice de seca pela diferença normalizada (NDDI) por imagens MOD09A1 processadas na plataforma Google Earth Engine (GEE) e no Software QGIS (2.18). Para a distribuição espacial dos rebanhos utilizou-se o banco de dados de produção pecuária municipal do SIDRA/IBGE. A análise comparativa mostrou que as classes seca extrema e seca excepcional foram maiores na 2ª série histórica, enquanto seca anormal teve maior área na 1ª série. A análise dos dados gerou informações como os locais mais propícios a criação de ovinos e de caprinos frente aos riscos de períodos de incertezas climáticas. No segundo capítulo foi feita a caracterização espectral por meio da sazonalidade do fator de refletância bidirecional de superfície e dos índices espectrais de vegetação de fragmentos de pastagens nativas, bem como a mudança do uso e ocupação do solo de regiões do bioma Caatinga. Foram utilizadas imagens do satélite Landsat-8 do período chuvoso e o período seco do ano de 2018 para verificar a sazonalidade da vegetação por meio da variação da refletância bidirecional de superfície das bandas espectrais e dos índices espectrais de vegetação (NDVI, SAVI, EVI, IAF, MSAVI<sub>2</sub> e NDWI). Com o intuito de obter a mudança da ocupação e uso do solo, foi utilizada a plataforma Google Earth Engine (GEE) e imagens Landsat-8 durante o período de 2014 a 2018. A validação do modelo de classificação por meio da matriz de confusão resultou numa exatidão global de 91% e índice Kappa de 89% em Tauá, e uma exatidão global de 90% e um índice Kappa de 86% em Ouricuri. A classificação de imagem por meio da ferramenta Google Earth Engine se mostrou eficaz em verificar a mudança temporal e espacial do uso e ocupação do solo, possibilitando identificar locais com vegetação mais afetada e susceptível à degradação. O terceiro capítulo testou a eficiência da modelagem empírica e mecanicística em simular a biomassa de forragem de pastagens nativa do bioma Caatinga e aplicá-los em mapas de produção de forragem. A estimativa da produção de biomassa da pastagem foi feita pela soma da biomassa herbácea e arbustivo-arbóreo. Para modelagem empírica foram utilizadas imagens do satélite Sentinel 2-A e testados os índices: NDVI, SAVI, EVI, IAF, MSAVI<sub>2</sub> e NDWI, através do LAB Fit Curve Fitting. A calibração do modelo PHYGROW foi realizada por meio da plataforma virtual PHYWEB. O SAVI foi o

índice que apresentou os melhores ajustes do modelo com média capacidade de simular a produção da biomassa de forragem total em pastagens naturais da Caatinga. O PHYGROW apresentou melhor desempenho em simular a produção de biomassa, mostrando-se ser útil para estimar a produção de biomassa de áreas de Caatinga com diferentes níveis de densidade lenhosa, tornando-se uma ferramenta útil para o manejo racional de pastagens.

**Palavras-chave:** Ajuste de taxa de lotação. Análise pecuária. Classificação de imagens. Índices espectrais de vegetação. Ocorrência de secas. Google Earth Engine.

## ABSTRACT

The aim of this study was to analyze the capacity of modeling and geoprocessing techniques in the generation of a protocol with early warning information for livestock farmers living in regions of the Caatinga Biome. The first chapter carried out a temporal analysis of droughts and the spatial distribution of herds in the Brazilian Semi-Arid region using geoprocessing tools. Annual maps of the vegetation index by the normalized difference (NDVI) and the drought index by the normalized difference (NDDI) maps were created using MOD09A1 images processed on the Google Earth Engine (GEE) platform and the QGIS Software (2.18). For the spatial distribution of herds, the municipal livestock production database of SIDRA/IBGE was used. The comparative analysis showed that the classes, extreme drought and exceptional drought were higher in the 2nd historical series, while abnormal drought had greater area in the 1st series. The analysis of the data generated information such as the most favorable places for the creation of sheep and goats in view of the risks of periods of climatic uncertainties. In the second chapter, spectral characterization was carried out through the seasonality of the bi-directional surface reflectance factor and the spectral indices of vegetation of fragments of native pastures, as well as the change in land use and occupation in regions of the Caatinga Biome. Images from the Landsat-8 satellite of the rainy season and the dry period of the year 2018 were used to verify the seasonality of the vegetation through the variation of the bidirectional reflectance of the surface of the spectral bands and the spectral indices of vegetation (NDVI, SAVI, EVI, IAF, MSAVI2 and NDWI). In order to obtain a change in land use and occupation, the Google Earth Engine (GEE) platform and Landsat-8 images were used during the period from 2014 to 2018. The validation of the classification model through the confusion matrix resulted in a global accuracy of 91% and Kappa index of 89% in Tauá, and global accuracy of 90% and Kappa index of 86% in Ouricuri. Image classification using the Google Earth Engine tool proved to be effective in verifying the temporal and spatial change in land use and occupation, making it possible to identify places with the most affected vegetation and susceptible to degradation. The third chapter tested the efficiency of empirical and mechanistic modeling in simulating forage biomass from native pastures of the Caatinga Biome and applying them to forage production maps. The estimate of pasture biomass production was based on the sum of herbaceous and shrub-tree biomass. For empirical modeling, images from the Sentinel 2-A satellite were used and the indices tested: NDVI, SAVI, EVI, IAF, MSAVI2 and NDWI, through the LAB Fit Curve Fitting. The calibration of the PHYGROW model was performed using the PHYWEB

virtual platform. The SAVI was the index that presented the best adjustments of the model with a medium capacity to simulate the production of total forage biomass in rangelands of the Caatinga. PHYGROW showed better performance in simulating biomass production, proving to be useful for estimating biomass production in areas of Caatinga with different levels of woody density, making it a useful tool for the rational management of rangelands.

**Keywords:** Adjustment of stocking rate. Google Earth Engine. Image classification. Livestock analysis. Occurrence of droughts. Spectral indexes of vegetation.

## LISTA DE FIGURAS

- Figura 1 – Fluxograma da estrutura integrada de um sistema de alerta precoce para monitoramento das pastagens em atividade pecuária ..... 24
- Figura 2 – Mapa de produção de forragem fornecidos aos pecuaristas da região de GOBI na Mongólia (A) e do norte e sul do Quênia (B)..... 25
- Figura 3 – Regiões do Brasil (A), os biomas (B) e altimetria (C) do Semiárido brasileiro..... 35
- Figura 4 – Polígonos em azul representam as unidades de conservação da região semiárida e os pontos amarelos (A) os locais de amostragem de dados de precipitação CHIRPS e dos índices espectrais de vegetação, e precipitação média anual (B) da região do Semiárido brasileiro..... 36
- Figura 5 – Fluxograma simplificado das etapas realizadas no Google Earth Engine e no Software livre QGIS versão 2.18..... 38
- Figura 6 – Variação e comparação estatística das classes de indicadores de severidade de seca (A-C) e de vigor da vegetação NDVI (B-D). Valores com letras distintas dentro da mesma classe não diferem entre si pelo teste T pareado. \*P< 0.01; \*\*P<0.05; \*\*\*P<0.10; <sup>NS</sup>P>0,10..... 42
- Figura 7 – Mapas da distribuição das classes de indicadores de seca palmer na região do Semiárido brasileiro a partir de dados MOD09A1..... 44
- Figura 8 – Mapas temáticos de classes de vigor da vegetação com base no NDVI obtidos por imagens MOD09A1 para a região do Semiárido brasileiro..... 45
- Figura 9 – Correlação de Spearman entre a precipitação CHIRPS e os índices espectrais de vegetação utilizados no presente estudo..... 46
- Figura 10 – Descrição da variação populacional dos rebanhos de ovinos (A), bovinos (B) e caprinos (C) expressos em % do rebanho nacional (barras verticais) e em animais/km<sup>2</sup> no Semiárido brasileiro (linhas), e comparação estatística da 1º e 2º séries históricas por meio do teste T pareado (D). Valores com letras distintas dentro da mesma classe não diferem entre si pelo teste T pareado. \*P< 0.01; \*\*P<0.05; \*\*\*P<0.10; <sup>NS</sup>P>0,10..... 47
- Figura 11 – Mapas da distribuição geográfica e mudança temporal dos rebanhos

bovinos, caprinos e ovinos (animais/km <sup>2</sup> ) da região do semiárido brasileiro por meio do processamento de dados do Sidra/IBGE.....	50
Figura 12 – Biomas integrantes da região do nordeste brasileiro (A), municípios que foram estabelecidas as vegetações para a análise espectral: Tauá (B) no Estado do Ceará e Ouricuri (C) no Estado de Pernambuco.....	61
Figura 13 – Vegetação nativa da Caatinga com a presença de bovinos pastejando (A). B e C correspondem a OD292 período chuvoso e seco, D e E correspondem a TD144 período chuvoso e seco; F e G à TD280 período chuvoso e seco.....	62
Figura 14 – Precipitação média anual dos municípios de Ouricuri e Tauá. Dados provenientes da Climate Hazards Group Infrared Precipitation (Para mais informações sobre o banco de dados CHIRPS consulte o capítulo 1 dessa tese).....	62
Figura 15 – Fluxograma simplificado das etapas realizadas para geração dos mapas de uso e ocupação do solo.....	65
Figura 16 – Fator de refletância bidirecional de superfície (FRBS) de fragmentos de pastagens com diferentes densidades da vegetação lenhosa nos municípios de Ouricuri e Tauá no período chuvoso (A) e seco do ano (B) de 2018.....	68
Figura 17 – Índices espectrais de vegetação aplicados a fragmentos de pasto nativo com diferente densidade lenhosa em Ouricuri e Tauá. Valores com letras distintas dentro de um mesmo índice diferem entre si pelo teste t de Wilcoxon (P<0,05).....	69
Figura 18 – Mapas temáticos do uso e ocupação do solo dos municípios de Tauá (A-B) e Ouricuri (D-E) entre os anos de 2014 e 2018, e mudança interanual (%) das classes de Tauá (C) e Ouricuri (F).....	72
Figura 19 – Limites geográficos dos municípios de Tauá e Ouricuri, e os transetos permanentes com diferentes densidades da vegetação lenhosa em Tauá (A e B) e Ouricuri (C e D).....	83
Figura 20 – Transeto permanente do tipo quadrante (A), e suas dimensões (B), moldura utilizada para colheita da biomassa herbácea de 0,25m <sup>2</sup> (C) e moldura utilizada para colheita da biomassa lenhosa de 20m <sup>2</sup> (D).....	85

Figura 21 – Biomassa de forragem total e índices espectrais de vegetação (NDVI, SAVI, EVI, IAF, MSAVI <sub>2</sub> e NDWI) obtidos a partir de dados Sentinel 2-A colhidos em vegetações nativas do bioma Caatinga. Vegetações: TD144 (A) e TD280 (B) OD372 (C) e TD212 (D).....	86
Figura 22 – Precipitação média mensal (mm), temperatura máxima, média e mínima (°C) e umidade do solo durante o período de coletas de dados no campo (2018-2019) em Tauá (A-B) e Ouricuri (C-D). Dados obtidos na plataforma PHYWEB.....	88
Figura 23 – Correlação de Spearman entre a biomassa de forragem colhida em pastos nativos da Caatinga e os índices espectrais de vegetação.....	91
Figura 24 – Modelos empíricos para simulação da biomassa de forragem total com base em índices de espectrais de vegetação obtidos de imagens do Sentinel-2A e dados de campo colhidos em Tauá e Ouricuri.....	92
Figura 25 – Curva de simulação de biomassa obtida por meio do modelo PHYGROW (kg.ha <sup>-1</sup> de MS) em vegetações de Caatinga com diferente densidade lenhosa: TD144 (A) e TD280 (B) OD212 (C) e TD372 (D) (●) Dados coletados em campo (2018 e 2019).....	94
Figura 26 – Comparação dos valores observados com os simulados pelo modelo PHYGROW (kg.ha <sup>-1</sup> ) durante a validação. (●) Dados coletados em campo e as barras correspondem ao erro padrão.....	95
Figura 27 – Mapas de produção de forragem para os municípios de Ouricuri (A) e Tauá (B) obtidos trimestralmente durante os anos de 2018 e 2019.....	97

## LISTA DE TABELAS

Tabela 1 – Índices espectrais de vegetação utilizados neste capítulo.....	39
Tabela 2 – Descrição e intervalo das classes de NDVI para condição do vigor da vegetação da região semiárida brasileira.....	39
Tabela 3 – Classificação dos indicadores de severidade de seca.....	40
Tabela 4 – Índices espectrais de vegetação utilizados para caracterização espectral das vegetações.....	64
Tabela 5 – Caracterização das classes de uso e ocupação do solo usadas neste estudo e a quantidade pontos definidos durante a amostragem de treinamento da classificação.....	66
Tabela 6 – Mudança da cobertura do solo (km <sup>2</sup> e em %), obtidos através de imagens Landsat 8 (OLI) processadas na plataforma Google Earth Engine.....	71
Tabela 7 – Matriz de confusão e os erros de omissão e de comissão obtidos por meio da comparação da classificação em Google Earth Engine (esquerda) com os dados de validação observados (topo) para o ano de 2018.....	73
Tabela 8 – Dados climáticos dos municípios localizados os sítios ecológicos para coleta de biomassa de forragem no campo (dados históricos do INMET - 2000 à 2020).....	84
Tabela 9 – Cobertura de monocotiledôneas, dicotiledôneas, serrapilheira e rochas, expressas em % e informações adicionais dos grupos funcionais para fins de parametrização do modelo PHYGROW. ....	88
Tabela 10 – Descrição das estatísticas utilizadas para a medida do desempenho dos modelos em simular a produção de biomassa do pasto nativo no bioma Caatinga.....	90



## SUMÁRIO

1	<b>INTRODUÇÃO GERAL</b> .....	19
2	<b>CAPÍTULO I: ANÁLISE DA DISTRIBUIÇÃO DAS SECAS E SEUS EFEITOS SOBRE A PECUÁRIA DA REGIÃO SEMIÁRIDA BRASILEIRA ATRAVÉS DE FERRAMENTAS DE GEOPROCESSAMENTO</b> .....	31
2.1	<b>Introdução</b> .....	33
2.2	<b>Material e Métodos</b> .....	35
2.2.1	<i>Local de estudo</i> .....	35
2.2.2	<i>Análise da distribuição geográfica da severidade da seca na região semiárida brasileira</i> .....	37
2.2.3	<i>Distribuição dos rebanhos por municípios da região semiárida</i> .....	40
2.2.4	<i>Análises estatística e correlação de Spearman entre precipitação e os índices espectrais de vegetação</i> .....	41
2.3	<b>Resultados e discussão</b> .....	41
2.3.1	<i>Distribuição das secas na região semiárida com dados MOD09A1 (2008-2017)</i> .....	41
2.3.2	<i>Mudança e distribuição dos rebanhos da região semiárida brasileira</i> .....	47
2.4	<b>Conclusão</b> .....	51
3	<b>CAPÍTULO II: CARACTERIZAÇÃO ESPECTRAL DE FRAGMENTOS DE PASTAGEM NATIVA E MUDANÇA DO USO E OCUPAÇÃO DO SOLO EM REGIÕES DO BIOMA CAATINGA</b> .....	57
3.1	<b>Introdução</b> .....	59
3.2	<b>Material e métodos</b> .....	61
3.2.1	<i>Caracterização da área de estudo</i> .....	61
3.2.2	<i>Caracterização espectral de fragmentos de pastagens nativas</i> .....	63
3.2.3	<i>Análise da mudança do uso e ocupação do solo de municípios localizados no bioma Caatinga</i> .....	65
3.3	<b>Resultados e Discussão</b> .....	67
3.3.1	<i>Caracterização espectral e índices de vegetação de fragmentos de pastagens</i> .....	67

	<i>nativas do bioma Caatinga</i> .....	
3.3.2	<i>Uso e ocupação do solo em regiões do bioma Caatinga</i> .....	71
3.4	<b>Conclusão</b> .....	74
4	<b>CAPÍTULO III: ANÁLISE DE TÉCNICAS DE MODELAGEM PARA SIMULAÇÃO DA BIOMASSA FORRAGEIRA E MAPAS DE PRODUÇÃO DE FORRAGEM EM REGIÕES DO BIOMA CAATINGA</b> .....	79
4.1	<b>Introdução</b> .....	81
4.2	<b>Material e métodos</b> .....	83
4.2.1	<i>Localização e caracterização climática da área experimental</i> .....	83
4.2.2	<i>Avaliação da vegetação</i> .....	84
4.2.3	<i>Geração de modelos empíricos a partir de dados de sensoriamento remoto</i> ...	86
4.2.4	<i>Calibração do modelo PHYGROW</i> .....	87
4.2.5	<i>Estatísticas utilizadas para avaliação dos modelos de simulação</i> .....	89
4.2.6	<i>Mapas de produção de forragem</i> .....	90
4.3	<b>Resultados e Discussão</b> .....	91
4.3.1	<i>Geração e validação de modelos empíricos</i> .....	91
4.3.2	<i>Calibração e validação do modelo PHYGROW</i> .....	93
4.3.3	<i>Aplicação de modelo empírico na produção de mapas de biomassa de forragem</i> .....	96
4.4	<b>Conclusão</b> .....	98
5	<b>CONSIDERAÇÕES FINAIS E IMPLICAÇÕES</b> .....	99
	<b>REFERÊNCIAS</b> .....	100

## 1. INTRODUÇÃO GERAL

As secas em regiões áridas e semiáridas do mundo estão cada vez mais comuns e os sistemas de produção agrícola precisam estar adaptados aos padrões locais de variabilidade climática (DÍAZ-SOLÍS et al., 2009). Segundo Adams et al. (2003), as agências meteorológicas de todo o mundo estão buscando métodos para determinar como as perturbações climáticas podem ser detectadas com antecedência suficiente para que se possa tomar decisões e evitar prejuízos. Sabe-se que a variabilidade climática vem sendo atribuídas principalmente as emissões de gases de efeito estufa, sendo uma das principais causas que aumentam as incertezas na produção animal (ANGERER et al., 2014).

As secas meteorológicas referem-se à deficiência hídrica, que possivelmente vem associada com o aumento da evapotranspiração e afeta a vegetação em extensas áreas por um longo tempo (BARBOSA et al., 2019), comprometendo a sustentabilidade dos recursos hídricos, da pecuária e da agricultura (SHAHABFAR & EITZINGER, 2011). Porém, isoladamente, as secas não significam ocorrência de desastres (RENZA et al., 2010), pois tratam-se de eventos naturais que seus prejuízos podem ser ou não agravados pela ação do homem (SHEFFIELD & WOOD, 2008).

No Semiárido brasileiro, a maior frequência e duração dos eventos, como a seca, estão associados ao aumento da temperatura e a sua interação com práticas insustentáveis de manejo do solo podem resultar num maior risco de desertificação da região (MARENGO et al., 2017). Nesta região o bioma predominante é a Caatinga, que, segundo Silva et al. (2020), é um dos mais ameaçados pela incidência de secas, logo a maior parte da vegetação nativa foi desmatada principalmente para a formação de áreas de pastagem, em resposta à demanda imposta pela atividade pecuária da região. Em contrapartida, a pecuária da região semiárida é uma das atividades sócio-econômicas mais importantes para a região, com destaque a criação de bovinos, caprinos e ovinos, que é praticada ao longo de toda a extensão territorial (SANTOS et al., 2011).

A pecuária contribui diretamente para a subsistência e a segurança alimentar de quase um bilhão de pessoas no mundo (ROBINSON et al., 2014), de modo que, quando pensamos especialmente em produção de ruminantes, estes animais possuem a capacidade de transformar a fibra da forragem em alimentos ricos em nutrientes de alta qualidade para a alimentação humana (SMITH et al., 2013). Em algumas regiões do planeta, principalmente onde a pecuária é realizada em pastagens nativas, estas também fornecem outros serviços ao meio ambiente, por exemplo: produção de fibra, sequestro de carbono, conservação de

recursos naturais e atividades de recreação.

Porém, a principal utilidade das pastagens nativas é dar suporte a atividade pecuária. Estima-se que cerca de 30% da população mundial depende da pecuária em pastagens nativas para geração de renda e atividade econômica (REYNOLDS et al., 2007), especialmente para as comunidades rurais da África (SIBANDA et al., 2017), regiões áridas e semiáridas do mundo (HE et al., 2005), que são as principais regiões que enfrentam maiores problemas por atividades antrópicas, mudanças climáticas, desastres naturais e desigualdades socioeconômicas. Segundo Verstraete et al. (2009), as regiões áridas e semiáridas do mundo estão intimamente relacionadas com a pobreza global e a atividade pecuária, mesmo que pouco produtiva, é muitas vezes a única fonte de renda para os moradores destas regiões.

Na região do Semiárido brasileiro a vegetação predominante é a floresta seca tropical sazonal chamada de Caatinga (CASTANHO et al., 2020). Ao longo dos anos, as atividades antrópicas como desmatamento, agricultura e pecuária mudaram a paisagem da Caatinga e alguns casos contribuíram para o processo de erosão, assoreamento de rios e até mesmo desertificação (SAMPAIO et al., 2008). Segundo Araújo Filho (2013), a diversidade da Caatinga constitui uma característica importante, pois uma Caatinga com alta diversidade apresenta melhor resiliência podendo reverter com maior facilidade os efeitos destrutivos das alterações ambientais, mantendo a conservação da biodiversidade da cobertura florística, enriquecida com a ocorrência significativa de forrageiras nativas, sobressai-se como a meta mais importante a ser alcançada pelo manejo da pastagem nativa.

Com relação à degradação da Caatinga, para Ribeiro et al. (2015) o sobrepastoreio e a extração ilegal de madeira florestal são os principais motores, levando a extinção de espécies vegetais bem como a ocorrência de alterações estruturais da vegetação. A pecuária tem provocado avanços na degradação da Caatinga, pois geralmente o sobrepastejo da vegetação nativa provoca a quebra da capacidade de crescimento das plantas através dos nutrientes acumulados no resíduo pós-pastejo e o período de descanso, pois há a eliminação de muitos pontos de crescimento e, quando novas brotações surgem, são rapidamente consumidas pelos animais. Portanto, o monitoramento da produção do pasto nativo é de fundamental importância, uma vez que a biomassa oscila ao longo do ano e, como consequência, a taxa de lotação precisa ser reajustada com frequência para aumentar ou diminuir o número de animais de acordo com a biomassa forrageira presente no pasto. Então o que se busca é a intensificação sustentável, como um modelo de produção que aumente a produtividade animal, sem causar impacto ambiental negativo no bioma Caatinga.

A forragem é a principal fonte de alimento para os herbívoros domésticos, e o pastejo

é o meio pelo qual os animais apreendem a forragem (RAO et al., 2015). O pastejo abrange interações entre o animal e seu ambiente (PROVENZA et al., 2015), e essa interação depende essencialmente da oferta de forragem presente na pastagem. Segundo Allen et al. (2011), o manejo do pastejo consiste na manipulação do pastejo animal em busca de um objetivo definido, sendo que este objetivo busca maximizar a transformação da forragem presente no pasto em produto animal, mantendo-se a perenidade do pasto, através da contínua emissão de folhas e perfilhos após o pastejo, restaurando a área foliar da vegetação (DA COSTA ARAÚJO et al., 2015).

Uma característica relevante da produção animal em pastagens nativas é a baixa taxa de lotação das pastagens (SAYRE et al., 2013). Deste modo, o conhecimento da variação da biomassa presente na pastagem é decisivo para o planejamento de um manejo racional, principalmente por ser através desta informação que se realiza o ajuste da disponibilidade de forragem a uma taxa de lotação adequada (CAUDURO et al., 2007), de modo que o uso de uma taxa de lotação mal ajustada pode gerar problemas em grande escala, podendo chegar até à degradação da pastagem (GEIST & LAMBIN, 2004).

À medida que aumenta a taxa de lotação, o desempenho individual por animal diminui, enquanto a produção por área aumenta e depois tende a diminuir em função da concorrência que controla a produção e a utilização da forragem pelo animal em pastejo (DE FACCIO CARVALHO & BATELLO, 2009). Quando a taxa de lotação está acima da capacidade de suporte da pastagem e não é realizado o monitoramento da condição produtiva da biomassa de forragem, ocorre uma alta intensidade de pastejo na vegetação, que compromete o equilíbrio entre a produção de biomassa e a rebrota da pastagem (CHANG et al., 2016).

Então, o monitoramento frequente da biomassa pretende ajustar à quantidade de animais a capacidade de suporte da pastagem, sabendo que uma quantidade de animais acima da capacidade de suporte acarreta o sobrepastejo da vegetação, e com este a degradação da pastagem. Existem métodos diretos e indiretos para estimativa da produção de biomassa em ambientes pastoris, porém os métodos indiretos estão sendo mais estudados, principalmente devido ao método direto ser baseado no corte total da forragem (MORAIS et al., 2018).

Método direto é baseado no corte de toda a forragem contida numa moldura de área conhecida e de formato quadrado, retangular ou circular, sendo que o formato depende muito da condição de homogeneidade da vegetação. A partir da biomassa presente nesta moldura, e desde que o local escolhido para a amostragem seja representativo da área de pastagem, pode-se extrapolar o valor obtido para kg/ha de matéria seca produzida. A partir das limitações para colheita de biomassa das pastagens pelo método direto, outros métodos passaram a ser

estudados e aperfeiçoados com o intuito de estimar a biomassa de forragem de forma indireta, sem a necessidade do corte direto da forragem, e que possibilite relacionar características fáceis e rápidas de serem medidas no campo (ZHANG et al., 2016).

Pensando em pastagens nativas da Caatinga, o monitoramento da vegetação realizado diretamente no campo não é capaz de verificar mudanças na estrutura e dinâmica da vegetação em larga escala de monitoramento, o que vem reforçando a necessidade de buscar alternativas mais práticas e eficientes, como as ferramentas de modelagem e de sensoriamento remoto utilizando imagens de satélite (SILVA et al., 2020). Além disso, o avanço da computação, a disponibilidade de sistemas de informação geográfica, as imagens de satélite, a modelagem biofísica e os dados meteorológicos em tempo quase real têm sido úteis na avaliação do impacto das condições climáticas sobre a produção das pastagens (ALHAMAD et al., 2007).

Conceitualmente, os modelos consistem em representações de fenômenos naturais (TEDESCH, 2006). Segundo Almeida et al. (2011), geralmente os modelos são baseados em variáveis edafoclimáticas e definidos a partir de uma informação de base necessária para que a planta atinja um determinado estágio de crescimento. Esses modelos de simulação possuem níveis diferentes de complexidade e muitos são projetados não apenas para simular a produção de biomassa, mas para examinar outros aspectos como hidrologia, erosão, desempenho dos animais, eficiência econômica do sistema em uma estrutura integrada e interativa (ANGERER et al., 2014).

Segundo Bryant & Snow (2008), um sistema de produção animal em pastagem é de difícil representação através da modelagem, uma vez que este sistema agrega plantas, animais, solo e o clima, em que estes componentes são manipulados por decisões gerenciais e todos os processos afetam o ecossistema. Os modelos precisam integrar conhecimentos multidisciplinares, como os de física e química do solo, clima, fisiologia e características das plantas as quais se pretende modelar a produção, e a sua aplicação pode auxiliar na geração de informações necessárias para a definição de políticas agrícolas, zoneamento agroclimático, estudos de mudanças climáticas e planejamento de produção (ANDRADE et al., 2016).

As informações obtidas por meio do desenvolvimento e do aperfeiçoamento de modelos para representar a vegetação da Caatinga podem orientar os pecuaristas a realizar o ajuste da taxa de lotação das pastagens nativas. Além disso, os modelos de simulação possuem a capacidade de verificar antecipadamente os efeitos das mudanças climáticas sobre os sistemas de produção (TIETJEN & JELTSCH, 2007), principalmente por meio da visualização do comportamento produtivo do modelo em função da alteração do clima e a partir destas

informações auxiliarem o governo no desenvolvimento de políticas públicas, como também na realização de planos para prever a ocorrência de desastres por incidência de secas.

Para o desenvolvimento de modelos empíricos, a primeira etapa consiste na geração do modelo, que se refere à obtenção de equações matemáticas que quantifiquem a relações de causa-efeito entre variáveis mensuráveis. A geração do modelo se inicia com a obtenção de uma série de dados que representam essa relação de causa-efeito (SANDS & LANDSBERG, 2002). Já na validação, os dados estimados são comparados aos dados colhidos no campo através de análises estatísticas que demonstrarão a confiabilidade desta estimativa. Segundo Alvarado (2017), uma etapa bastante importante do processo de modelagem de simulação é a validação dos modelos, uma vez que esta etapa permite avaliar a qualidade de um modelo em função dos objetivos estabelecidos por meio da comparação dos dados reais com as saídas simuladas pelos modelos.

O sensoriamento remoto tem sido muito utilizado nos estudos que abordam a estimativa da biomassa forrageira com uso de modelagem empírica, e desde quando passou a ser predominantemente orbital, somado à facilidade de acesso à internet, tornou-se cada vez mais difundido e acessível (FERREIRA et al., 2008). Além disso, as imagens de satélite de alta resolução estão cada vez mais disponíveis para serem utilizadas de forma gratuita em diversas aplicações, tanto para estudos de pequena quanto de grande escala (FORQUOR et al., 2017), com aplicações nos estudos sobre vegetação, caracterização dos solos, estrutura da vegetação, disponibilidade hídrica, nutrientes e ciclo fenológico das plantas (BÉGUÉ et al., 2018).

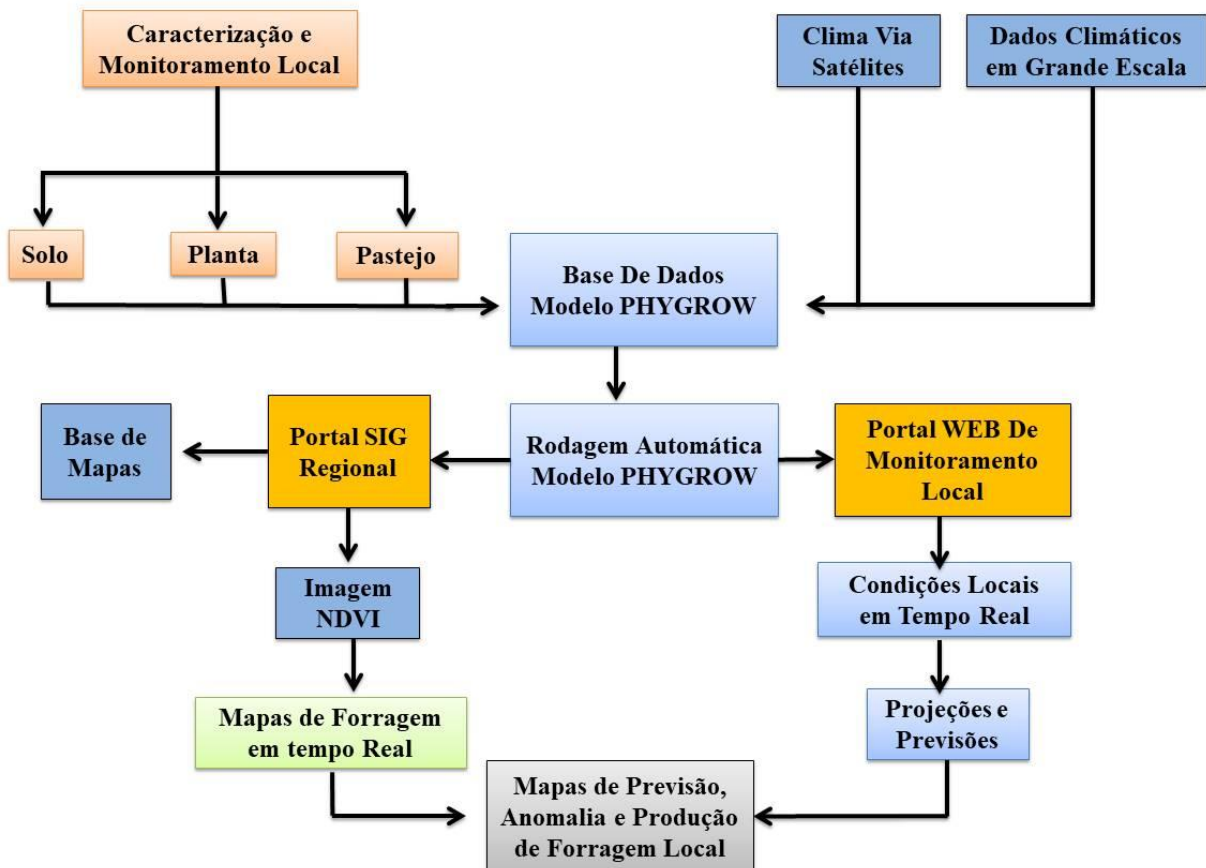
Uma informação importante nos estudos que caracterizam parâmetros biofísicos da vegetação por meio do sensoriamento remoto é o conhecimento do comportamento espectral dos alvos, pois através desta informação torna-se possível a interpretação do sensoriamento remoto, sabendo que a resposta da vegetação nas diferentes bandas espectrais permite a identificação e monitoramento da mesma. Portanto, a partir deste conhecimento criaram-se os índices espectrais com o interesse de investigar propriedades espectrais da vegetação. Estes índices consistem em modelos alimentados pelos valores de refletância contidos dos pixels das imagens de satélite. A maior parte dos índices espectrais utilizados nos estudos com vegetações são modelos desenvolvidos a partir das relações entre o vermelho, o infravermelho médio ou de ondas curtas, logo, estes possuem alta capacidade de verificar modificações nas vegetações.

Quando um modelo considera as leis da biologia, da química e da física para realizar a representação da dinâmica do sistema produção vegetal, este modelo é denominado de mecanicista. Existem vários modelos mecanicistas que já foram calibrados e validados em

pastos nativos do mundo, porém o PHYGROW é um modelo que tem sido amplamente difundido. Este modelo é utilizado em projetos de alerta precoce e no desenvolvimento de sistemas de monitoramento de produção de forragem em diversas regiões áridas e semiáridas do mundo (MATERE et al., 2019). Além disso, é a base para o projeto Livestock Early Warning System (LEWS), o qual desenvolve sistemas de monitoramento da produção de forragem em toda região leste do continente africano (KAITHO et al., 2007), Mongólia (ANGERER, 2012) e nos Estados Unidos (ANGERER, 2008).

É possível verificar numa representação estrutura (Figura 1) do funcionamento do projeto Livestock Early Warning System a combinação de coleta de dados de campo, modelagem de simulação, técnicas geoestatísticas e sistemas de informação geográfica para realizar a geração de mapas de produção de forragem regional e previsões (ANGERER, 2012).

Figura 1 - Fluxograma da estrutura integrada de um sistema de alerta precoce para monitoramento das pastagens em atividade pecuária

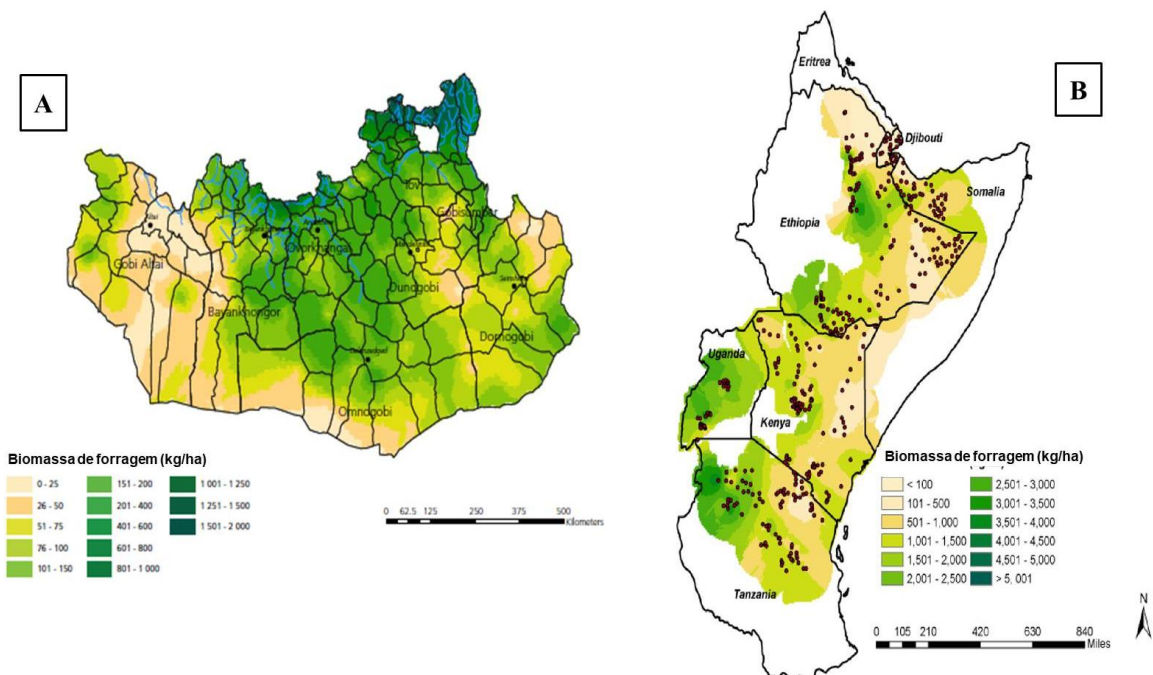


Fonte: Adaptado de Angerer (2012).



O sistema de alerta precoce busca fornecer de forma contínua informações sobre a produção de forragem, possibilitando que os pecuaristas identifiquem momentos adversos, acionando tomadas de decisões apropriadas e oportunas (STUTH et al., 2005). Em algumas regiões da África, onde os criadores são nômades, e movimentam os seus rebanhos de acordo com a produção das pastagens, este sistema possibilita que os produtores tenham a liberdade de se deslocar (MORITZ et al., 2013), sempre buscando locais em que haja maior oferta de forragem para os animais. Para isso, são produzidos mapas de produção de forragem (Figura 2 A e B) indicando os locais que há melhores ou piores condições das pastagens e classificá-los quanto a maior ou menor probabilidade de ocorrência de desastres pela incidência de secas. Após a produção dos mapas, estes são disponibilizados aos pecuaristas via internet (ANGERER, 2012).

Figura 2 - Mapa de produção de forragem fornecidos aos pecuaristas da região de GOBI na Mongólia (A) e do norte e sul do Quênia (B)



Fonte: O mapa A é uma adaptação de Angerer (2012) e o mapa B de Angerer et al. (2014).

A criação animal é uma das principais fontes de renda para as pessoas residentes em regiões do Quênia e da Mongólia (Figura 2A e B), de modo que o fornecimento de informações sobre previsão de secas ou de desastres ajuda os pecuaristas com informações úteis nas tomadas de decisão (ANGERER, 2012). A partir dos mapas de produção de forragem os pecuaristas realizam os ajustes da taxa de lotação das pastagens, bem como se

planejam para estocar alimentos para uso em época de escassez caso tenham forragem excedente.

Angerer (2012) realizou uma pesquisa com os participantes do projeto alerta precoce realizado na Mongólia, e os resultados mostraram que o sistema contribui com informações úteis para 70% dos pecuaristas da região, orientando os produtores com informações sobre suplementação das pastagens ou ajustes na taxa de lotação. Segundo Angerer et al. (2014), os futuros esforços dos sistemas de alerta precoce irão se concentrar no treinamento de ferramentas de Sistemas de Informação Geográfica associados à plataforma da internet, com o intuito de acelerar o fluxo de dados e a consulta das informações através de smartphones ou tablets dos usuários locais. Segundo Kaitho et al. (2007), é importante o desenvolvimento da pesquisa integrada na pecuária, pois esta categoria de pesquisa gera tecnologias que associam várias informações importantes conjuntas, além de ser uma maneira prática e resumida de apoiar os pecuaristas na tomada de decisão. Com base no exposto, o objetivo deste estudo foi realizar análises através de ferramentas de geoprocessamento e modelagem sobre a distribuição das secas e seus efeitos sobre a pecuária da região semiárida brasileira. Além disso, foram estabelecidas as características espectrais de pastagens nativas e a análise da mudança no uso do solo em regiões do bioma Caatinga; e por último foi medida a capacidade de técnicas de modelagem em simular a produção de biomassa forrageira, como também aplicá-los no desenvolvimento de mapas de produção de forragem como proposta de informações de alerta precoce aos pecuaristas residentes em regiões do bioma Caatinga.

## REFERÊNCIAS

- ADAMS, Richard M. et al. The benefits to Mexican agriculture of an El Niño-southern oscillation (ENSO) early warning system. **Agricultural and Forest Meteorology**, Amsterdam, v. 115, n. 3-4, p. 183-194, 2003.
- ALHAMAD, M.N.; STUTH, J.; VANNUCCI, M. Biophysical modelling and NDVI time series to project near-term forage supply: spectral analysis aided by wavelet denoising and ARIMA modelling. **International Journal of Remote Sensing**, Abingdon, v. 28, n. 11, p. 2513-2548, 2007.
- ALLEN, Vivien Gore et al. An international terminology for grazing lands and grazing animals. **Grass and forage science**, Hoboken, v. 66, n. 1, p. 2, 2011.
- ALMEIDA, Alexsandro Claudio dos Santos et al. Simulação do crescimento do capim Tanzânia irrigado com base na unidade fototérmica, na adubação nitrogenada e na disponibilidade hídrica do período. **Acta Scientiarum. Agronomy**, Maringa, 2011, v. 33, n. 2, p. 215-222.
- ALVARADO, Christiam Segundo Morales. **Estudo e implementação de métodos de validação de modelos matemáticos aplicados no desenvolvimento de sistemas de controle de processos industriais**. 2017. Tese de Doutorado. Universidade de São Paulo.
- ANDRADE, A. S. et al. Simulating tropical forage growth and biomass accumulation: an overview of model development and application. **Grass and Forage Science**, Hoboken, v. 71, n.1, pp. 54-65, 2016.
- ANGERER, Jay Peter. **Examination of high resolution rainfall products and satellite greenness indices for estimating patch and landscape forage biomass**. 2010. Tese de Doutorado. Texas A & M University.
- ANGERER, Jay P. 12. gobi forage livestock Early warning System. **NATIONAL FEED ASSESSMENTS**, p. 115, 2012.
- ANGERER, Jay P.; BIZIMANA, J. C. B.; ALEMAYEHU, Sintayehu. Reducing risk in pastoral regions: the role of early warning and livestock information systems. **Revista Científica de Produção Animal**, Areia, v. 15, n. 1, p. 9-21, 2014.
- ARAÚJO FILHO, João Ambrosio. **Manejo pastoril sustentável da caatinga**. v. 01, Cidade Gráfica e Editora Ltda., pp. 200, 2013.
- DA COSTA ARAÚJO, Daniel Louçana et al. Características morfogênicas, estruturais e padrões demográficos de perfilhos em pastagem de capim-andropógon sob diferentes ofertas de forragem. **Semina: Ciências Agrárias**, Londrina, v. 36, n. 5, p. 3303-3314, 2015.
- BARBOSA, Humberto Alves et al. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008-2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 1, n. 2, p. 1-18, 2019.

BÉGUÉ, Agnès et al. Remote sensing and cropping practices: A review. **Remote Sensing**, Basel, v. 10, n. 1, p. 99, 2018.

BRYANT, J. R.; SNOW, V. O. Modelling pastoral farm agro-ecosystems: a review. **New Zealand Journal of Agricultural Research**, Abingdon, v. 51, n. 3, p. 349-363, 2008.

DE FACCIO CARVALHO, Paulo César; BATELLO, Caterina Access to land, livestock production and ecosystem conservation in the Brazilian Campos biome: the natural grasslands dilemma. **Livestock Science**, Amsterdam, v. 120, n. 1-2, p. 158-162, 2009.

CASTANHO, Andrea DA et al. close look at above ground biomass of a large and heterogeneous Seasonally Dry Tropical Forest-Caatinga in North East of Brazil. **Academia Brasileira de Ciências**, Rio de Janeiro, v. 92, n. 1, 2020.

CAUDURO, Guilherme Fernandes et al. Fluxo de biomassa aérea em azevém anual manejado sob duas intensidades e dois métodos de pastejo. **Revista Brasileira de Zootecnia**, Viçosa, v. 36, n. 2, p. 282-290, 2007.

CHANG, Jinfeng et al. Combining livestock production information in a process-based vegetation model to reconstruct the history of grassland management. **Biogeosciences**, Göttingen, v. 13, n. 12, p. 3757-3776, 2016.

DÍAZ-SOLÍS, H. et al. Adaptive management of stocking rates to reduce effects of drought on cow-calf production systems in semi-arid rangelands. **Agricultural Systems**, Amsterdam, v. 100, n. 1-3, p. 43-50, 2009.

FERREIRA, Laerte Guimarães; FERREIRA, Nilson Clementino; FERREIRA, Manuel Eduardo. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, Maringa, v. 30, n. 4, p. 379-390, 2008.

FORKUOR, Gerald et al. Landsat-8 vs. Sentinel-2: examining the added value of sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. **GIScience & Remote Sensing**, Abingdon, v. 55, n. 3, p. 331-354, 2017.

GEIST, Helmut J.; LAMBIN, Eric F. Dynamic causal patterns of desertification. **Bioscience**, Oxford, v. 54, n. 9, p. 817-829, 2004.

HE, Chunyang et al. Zoning grassland protection area using remote sensing and cellular automata modeling—a case study in Xilingol steppe grassland in northern China. **Journal of Arid Environments**, Londres, v. 63, n. 4, p. 814-826, 2005.

KAITHO, R. J. et al. Livestock early warning information resource in the Horn of Africa: forage and livestock marketing information analysis and forecasts. **Outlook on Agriculture**, Thousand Oaks, v. 36, n. 4, p. 267-272, 2007.

MARENGO, Jose A.; TORRES, Roger Rodrigues; ALVES, Lincoln Muniz. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, Berlin, v. 129, n. 3-4, p. 1189-1200, 2017.

MARIN, Fábio R.; JONES, James W. Process-based simple model for simulating sugarcane

growth and production. **Scientia Agrícola**, Piracicaba, v. 71, n. 1, p. 1–16, 2014.

MATERE, Joseph et al. Predictive Livestock Early Warning System (PLEWS): Monitoring forage condition and implications for animal production in Kenya. **Weather and Climate Extremes**, Amsterdam, v. 27, p. 100209, 2020.

DE MORAIS, Leonardo Fiusa et al. Avanços na avaliação de pastagens cultivadas com forrageiras tropicais no Brasil: Uma Revisão. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, Guarapuava, v. 11, n. 2, 2018.

MORITZ, Mark et al. Open access, open systems: pastoral management of common-pool resources in the Chad Basin. **Human Ecology**, Berlin, v. 41, n. 3, p. 351-365, 2013.

PROVENZA, F. D.; GREGORINI, Pablo; CARVALHO, Paulo Cesar Faccio. Synthesis: foraging decisions link plants, herbivores and human beings. **Animal Production Science**, Sidney, v. 55, n. 3, p. 411-425, 2015.

RAO, Idupulapati M. et al. LivestockPlus—The sustainable intensification of forage-based agricultural systems to improve livelihoods and ecosystem services in the tropics. **Tropical Grasslands-Forrajes Tropicales**, Cali, v. 3, n. 2, p. 59-82, 2015.

RENZA, Diego et al. Drought estimation maps by means of multirate Landsat fused images. In: **Proceedings of the 30th EARSeL Symposium**. 2010.

REYNOLDS, James F. et al. Global desertification: building a science for dryland development. **Science**, Washington, v. 316, n. 5826, p. 847-851, 2007.

RIBEIRO, Elâine MS et al. Chronic anthropogenic disturbance drives the biological impoverishment of the Brazilian Caatinga vegetation. **Journal of Applied Ecology**, Londres, v. 52, n. 3, p. 611-620, 2015.

ROBINSON, Timothy P. et al. Mapping the Global Distribution of Livestock. **PLoS ONE**, San Francisco, v. 9, n. 5, p. 232-240, 2014.

SAMPAIO, Everardo VSB; MARIA DO SOCORRO, B. Araújo; SAMPAIO, Yony SB. Propensão à desertificação no semiárido brasileiro. **Revista de Geografia**, Recife, v. 22, n. 2, p. 59-76, 2008.

SANDS, P. J.; LANDSBERG, J. J. Parameterisation of 3-PG for plantation grown Eucalyptus globulus. **Forest Ecology and Management**, Amsterdam, v. 163, n. 1-3, p. 273-292, 2002.

SANTOS, Patricia Menezes et al. Mudanças climáticas globais e a pecuária: cenários futuros para o Semiárido brasileiro. **Revista Brasileira de Geografia Física**, Recife, v. 06, p. 1176-1196, 2011.

SAYRE, Nathan F. et al. Earth stewardship of rangelands: coping with ecological, economic, and political marginality. **Frontiers in Ecology and the Environment**, Washington, v. 11, n. 7, p. 348-354, 2013.

SHAHABFAR, A.; EITZINGER, J. Agricultural drought monitoring in semi-arid and arid

areas using MODIS data. **The Journal of Agricultural Science**, Cambridge, v. 149, n. 4, p. 403-414, 2011.

SHEFFIELD, Justin; WOOD, Eric F. Global trends and variability in soil moisture and drought characteristics, 1950–2000, from observation-driven simulations of the terrestrial hydrologic cycle. **Journal of Climate**, Massachusetts, v. 21, n. 3, p. 432-458, 2008.

SIBANDA, Mbulisi et al. Estimating biomass of native grass grown under complex management treatments using worldview-3 spectral derivatives. **Remote Sensing**, Basel, v. 9, n. 1, p. 55, 2017.

DA SILVA, Marcos Vinícius et al. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 19, p. 100353, 2020.

SMITH, Jimmy et al. Beyond milk, meat, and eggs: Role of live-stock in food and nutrition security. **Animal Frontiers**, Champaign, v. 3, p. 6–13, 2013.

STUTH, JERRY W. et al. Livestock early warning system for Africa rangelands. **Monitoring and predicting agricultural drought: a global study**. New York, NY, USA: Oxford, p. 283-296, 2005.

TEDESCHI, Luis Orlando. Assessment of the adequacy of mathematical models. **Agricultural Systems**, Amsterdam, v. 89, n. 2–3, p. 225-247, 2006.

TIETJEN, Britta; JELTSCH, Florian. Semi-Arid Grazing Systems and Climate Change: A Survey of Present Modelling Potential and Future Needs. **Journal of Applied Ecology**, Londres, v. 44, n.2, pp. 425 – 434, 2007.

VERSTRAETE, Michel M.; SCHOLE, Robert J.; SMITH, Mark Stafford. Climate and desertification: looking at an old problem through new lenses. **Frontiers in Ecology and the Environment**, Washington, v. 7, n. 8, p. 421-428, 2009.

ZHANG, Binghua et al. Application of synthetic NDVI time series blended from Landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, Basel, v. 8, n. 1, p. 10, 2016.

## **2 CAPÍTULO 1: ANÁLISE DA DISTRIBUIÇÃO DAS SECAS E SEUS EFEITOS SOBRE A PECUÁRIA DA REGIÃO SEMIÁRIDA BRASILEIRA ATRAVÉS DE FERRAMENTAS DE GEOPROCESSAMENTO**

### **RESUMO**

O objeto deste estudo foi realizar uma análise temporal (2008-2017) da distribuição das secas com dados de sensoriamento remoto, da distribuição espacial e da variação do rebanho bovino, caprino e ovino da região semiárida brasileira por ferramentas de geoprocessamento. Com o intuito de obter mapas anuais de vigor da vegetação, adotaram-se classes de índice de vegetação pela diferença normalizada (NDVI) e classes de índice de seca pela diferença normalizada (NDDI) para a região semiárida brasileira. O processamento das imagens ocorreu na plataforma Google Earth Engine (GEE) e no Software QGIS (2.18), onde foram gerados mosaicos anuais a partir de imagens MOD09A1. Para análise da variação dos rebanhos, utilizou-se o banco de dados de produção pecuária municipal do SIDRA/IBGE. Para fins de comparação temporal, criaram-se duas séries históricas sendo uma denominada de 1º série (2007-2011) e a outra de 2º série (2012-2016), comparando-se às duas por meio do Teste T pareado. A análise comparativa mostrou que as classes seca extrema e seca excepcional tiveram maiores áreas na 2º série, enquanto seca anormal teve maior área na 1º série. A correlação entre o NDDI e a precipitação CHIRPS foi moderada e negativa para NDDI, enquanto com NDVI e NDWI foi positiva e baixa. Com relação à análise dos rebanhos notou-se redução do rebanho bovino e aumento dos rebanhos caprinos e ovinos durante o período de estudo. Este estudo considera alta a capacidade dos índices NDDI e NDVI em monitorar a distribuição das secas na região semiárida brasileira. O geoprocessamento de dados SIDRA/IBGE possibilitou uma análise da distribuição espacial e da variação temporal dos rebanhos da região semiárida, e a análise dos dados gerou informações como os locais mais propícios ao crescimento da criação de ovinos e caprinos frente aos riscos de períodos de incertezas climáticas.

**Palavras-chave:** Análise pecuária, desastres ambientais, Google Earth Engine, índices espectrais de vegetação, ocorrência de secas.

## ABSTRACT

The aim of this study was to carry out a temporal analysis (2008-2017) of the distribution of droughts with data from remote sensing, the spatial distribution and the variation of the cattle, goat and sheep flock in the Brazilian semiarid region using geoprocessing tools. In order to obtain annual maps of vegetation vigor, classes of normalized difference vegetation index (NDVI) and classes of normalized difference drought index (NDDI) were adopted for the Brazilian semiarid region. The images were processed using the Google Earth Engine (GEE) platform and the QGIS Software (2.18), where annual mosaics were generated from MOD09A1 images. To analyze the variation in herds, the SIDRA/IBGE municipal livestock production database was used. For the purpose of temporal comparison, two historical series were created, one called the 1st series (2007-2011) and the other the 2nd series (2012-2016), and the comparison of the two was made by using the paired T-Test. The comparative analysis showed that the classes, extreme drought and exceptional drought had greater areas in the 2nd series, while abnormal drought had greater area in the 1st series. The correlation between NDDI and CHIRPS precipitation was moderate and negative for NDDI, while with NDVI and NDWI it was positive and low. Regarding the analysis of herds, a reduction in the bovine herd and an increase in goat and sheep herds during the study period were noted. This study considers high the capacity of the NDDI and NDVI indices to monitor the distribution of droughts in the Brazilian semiarid region. The geoprocessing of SIDRA / IBGE data enabled an analysis of the spatial distribution and temporal variation of the herds in the semi-arid region, and the analysis of the data generated information as the most favorable places for the growth of sheep and goat rearing in view of the risks of periods of uncertainty climate change.

**Keywords:** Droughts, environmental disasters, Google Earth Engine, livestock analysis, spectral indexes of vegetation.



## 2.1 INTRODUÇÃO

As regiões áridas e semiáridas do mundo enfrentam grandes problemas de degradação por atividades antrópicas, mudanças climáticas, desastres naturais e desigualdades socioeconômicas (HE et al., 2005). Estas regiões ocupam cerca de 60,95 milhões de km<sup>2</sup>, que correspondem a aproximadamente 41% da superfície terrestre, com uma população estimada de 2 bilhões de habitantes (PINHEIRO & NAIR, 2019).

No Brasil, existe uma grande faixa classificada como região semiárida, situada principalmente no Nordeste do país, onde residem cerca de 56 milhões de pessoas (ALBUQUERQUE & MELO, 2018), sendo considerada a mais populosa do mundo (MAIA et al., 2007). Em comparação com outras regiões semiáridas do mundo, a do Brasil apresenta várias características climatológicas extremas, como a intensa radiação associada à escassez hídrica, que desafia as atividades agrícolas e pecuária, deixando os rebanhos mais vulneráveis principalmente devido à oscilação na capacidade de suporte das pastagens. A produção de ruminantes é uma importante atividade cultural, social e econômica, desempenhando um papel crucial no desenvolvimento do Semiárido brasileiro (COSTA et al., 2008). Porém, as secas têm ocasionado modificações no padrão populacional dos rebanhos, principalmente devido às espécies ruminantes criadas nesta região possuírem diferentes mecanismos de adaptação aos ambientes secos.

O geoprocessamento consiste em operações necessárias para manipular dados geoespaciais (ZHAO et al., 2012). Para a análise desses dados por meio do geoprocessamento, há a necessidade do uso de ferramentas de Sistema de Informação Geográfica, os quais são muito úteis na confecção de produtos cartográficos e na caracterização dos sistemas de produção pecuários através do mapeamento. Um exemplo de aplicação do geoprocessamento em pecuária é o trabalho realizado por Robinson et al. (2014), que utilizaram o banco de dados GLW (Gridded Livestock of the World) e dados estatísticos da FAO (FAOSTAT) com o intuito de criar um modelo para representar a densidade populacional dos rebanhos do globo terrestre. Os autores obtiveram altas densidades de bovinos em regiões da Índia, na África Oriental (principalmente na Etiópia), no Norte da Europa e na América Sul e concluíram que a aplicação da ferramenta pode trazer benefícios de ordem ambiental, socioeconômica e antropogênica, servindo como auxílio na conferência da distribuição geográfica dos rebanhos e orientação de políticas públicas direcionadas aos criadores.

Uma ferramenta de geoprocessamento capaz de capturar de maneira consistente as características de grandes áreas da superfície terrestre é o sensoriamento remoto (LU et al., 2014). Por meio dessa ferramenta, é possível verificar a condição hídrica em grande escala,

apoiando o desenvolvimento sustentável e o gerenciamento da produção agrícola, bem como as incidências de secas (SHAHABFAR & EITZINGER, 2011). Além disso, a combinação de ferramentas de sistema de informação geográfica com dados de sensoriamento remoto possibilita entender os fenômenos que ocorrem na superfície terrestre em larga escala, relacionando-os a eventos naturais ou de atividade antrópica (MENDES et al., 2018).

A aplicação do sensoriamento remoto ocorre devido às variações das respostas espectrais dos alvos da superfície terrestre (WARREN & METTERNICHT, 2005). Todo alvo da superfície terrestre possui características de reflexão da radiação emitida e a interpretação do sensoriamento remoto se dá por processos de captação da refletância a partir de imagens de satélites orbitais. Segundo Ferreira et al. (2008) um avanço do sensoriamento remoto da vegetação foi o lançamento do sensor MODIS a bordo do satélite terra (Moderate Resolution Imaging Spectroradiometer), com resolução espacial de 250; 500 ou 1000 m.

As secas são caracterizadas através da sua duração, intensidade e distribuição espacial, logo as avaliações para quantificar os seus efeitos podem ser realizadas através de análises estatísticas de dados históricos de precipitação, dados de umidade do solo e diferentes índices espectrais de vegetação (RENZA et al., 2010). Vários índices espectrais têm sido utilizados para estimar informações das condições de produtividade e umidade das vegetações e relacioná-las com a incidência de secas, sendo que destes o índice de vegetação pela diferença normalizada (NDVI, BAJGAIN et al., 2015) e o índice de seca pela diferença normalizada (NDDI, GU et al., 2007) são bastante úteis para o monitoramento de secas através de sensoriamento remoto. Tavazohi & Nadoushan (2018) testaram a capacidade do NDDI em monitorar a condição de seca na região de Isfahan no Irã durante os anos de 2000 a 2015 e consideraram-no muito eficiente e aceitável em realizar previsões, uma vez que ele relaciona o NDWI, que indica mudanças na umidade da vegetação com o NDVI, que tem relação com o vigor e conteúdo de clorofila da vegetação.

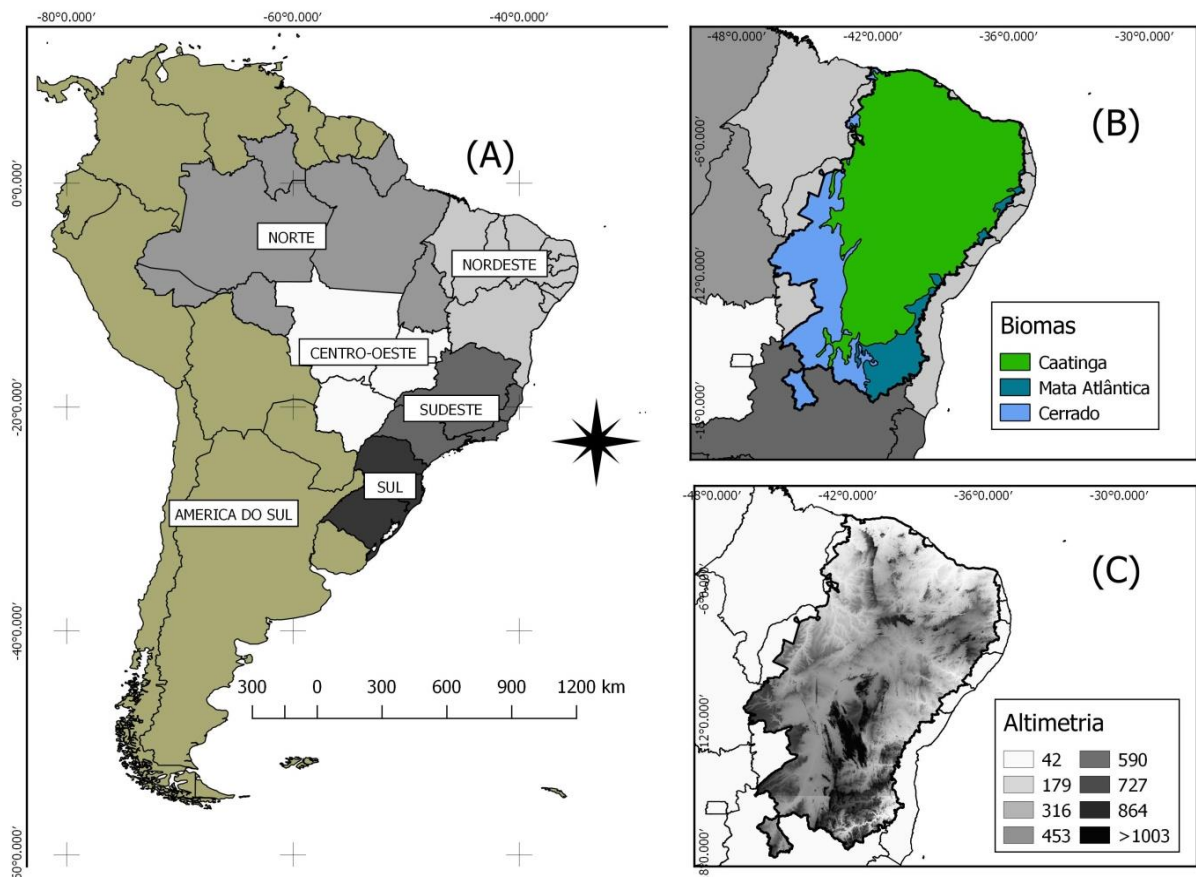
O objeto deste estudo foi realizar uma análise temporal (2008-2017) da distribuição das secas com dados de sensoriamento remoto e relacioná-la com a distribuição espacial e a variação dos rebanhos bovino, caprino e ovino do Semiárido brasileiro.

## 2.2 MATERIAL E MÉTODOS

### 2.2.1 Local de estudo

Para este estudo foram analisados os municípios pertencentes ao Semiárido brasileiro (Figura 3A). Foi utilizada a delimitação dessa região conforme a resolução CONDEL (Conselho Deliberativo da Superintendência do Desenvolvimento do Nordeste) número 115, de 23/11/2017, a qual estabeleceu seus limites com 1.262 municípios distribuídos em dez estados da Federação, ocupando uma área de cerca 1.128.697 km<sup>2</sup>.

Figura 3 – Regiões do Brasil (A), os biomas (B) e altimetria (C) do Semiárido brasileiro



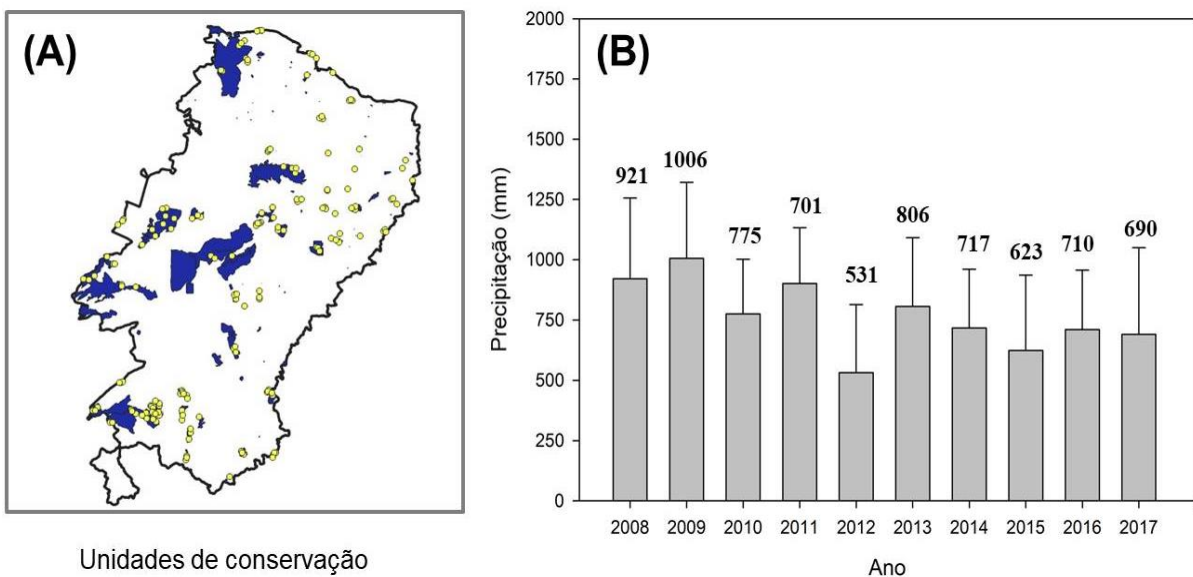
Fonte: Elaboração o autor.

Dos 1.128.697 km<sup>2</sup> cerca de 823.461 são do bioma Caatinga (72,95%), 239.133 km<sup>2</sup> do Cerrado (21,18%) e 91.913 km<sup>2</sup> de Mata Atlântica (8,14%). Como característica importante do Semiárido brasileiro, pode-se destacar a elevada radiação solar e temperatura ao longo do ano, com regime pluvial marcado por escassez e por irregularidade das precipitações, que na maior parte dos municípios é em torno de 750-800 mm (AB'SÁBER, 2003). Segundo Araújo Filho (2013), o período chuvoso do semiárido tem duração de 3 a 4 meses quando ocorrem cerca de 80% das precipitações anuais. Importante considerar que no Semiárido brasileiro,

mesmo durante a estação chuvosa, a evaporação é bastante intensa com relação às precipitações, e essa característica resulta em balanço hídrico negativo durante a maior parte do ano (DA SILVA, et al., 2020).

Foram criados 160 pontos aleatórios por meio da função criação de pontos aleatórios no interior do polígono presente no programa QGIS (2.18), considerando como polígonos os limites das unidades de conservação federal do Ministério do Meio Ambiente (BRASIL, 2020) para fim de amostragem de dados de precipitação CHIRPS e dos índices espectrais de vegetação utilizados neste estudo (Figura 4A). A Figura 4B apresenta a precipitação média anual para cada ano do referido estudo obtido por monitoramento de precipitação CHIRPS (Climate Hazards Group Infrared Precipitation) e coletados nos 160 pontos de monitoramento.

Figura 4 – Polígonos em azul representam as unidades de conservação da região semiárida e os pontos amarelos (A) os locais de amostragem de dados de precipitação CHIRPS e dos índices espectrais de vegetação, e precipitação média anual (B) da região do Semiárido brasileiro



Unidades de conservação  
Fonte: Elaboração o autor.

Os dados de precipitação CHIRPS consistem numa estimativa da precipitação por satélite, que neste estudo foi obtido no catálogo de imagens da Google Earth Engine. Estes dados são obtidos por meio do cálculo da precipitação diária, que em sequência é somado para geração da precipitação anual. Dados CHIRPS consistem num conjunto de informações de precipitação de mais de 30 anos de monitoramento, obtidos por imagens de satélite com

0,05 graus (5 km) de resolução espacial, com uma cobertura geográfica de 50°S a 50°N, com dados desde o ano de 1981 até os dias atuais.

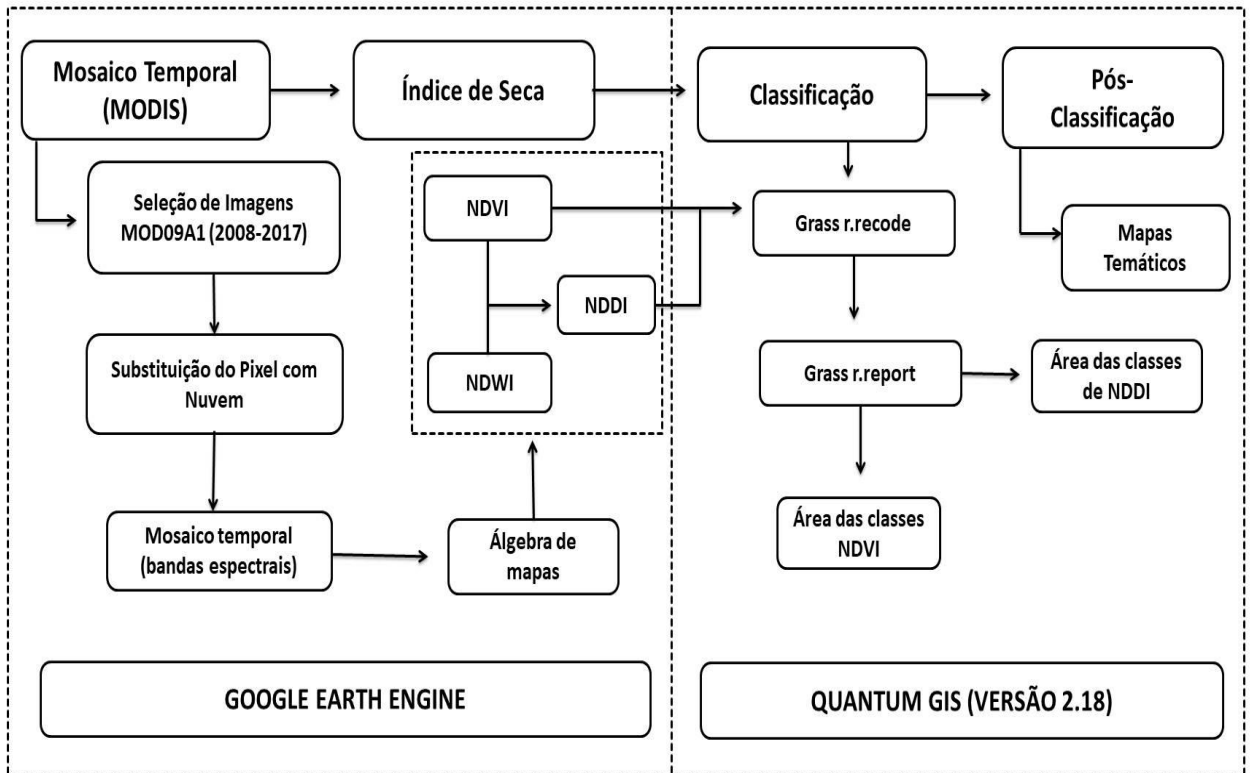
Os dados são frequentemente corrigidos com dados obtidos em estações meteorológicas com o objetivo principal de contribuir nas análises de previsões e monitoramento da seca, sendo que as estimativas são obtidas por meio de informações como: (I) The Climate Hazards Group's Precipitation Climatology (CHPClim); (II) Observações de satélites (NOAA) com espectroscopia de infravermelho termal (Thermal Infrared, TIR); (III) Campos de Precipitação do Coupled Forecast System da NOAA, versão 2 (CFSv2) e (IV) Observações de precipitação através de produtos de estações meteorológicas de serviços regionais (FUNK et al., 2015).

Com relação à representatividade dos dados CHIRPS para o Semiárido brasileiro, Paredes-Trejo et al. (2017) validaram o método CHIRPS de monitoramento da precipitação a partir de dados de precipitações coletadas em estações meteorológicas e concluíram que este método de monitoramento apresenta alta confiabilidade em representar a precipitação com uma correlação em torno de 0,94, mas havendo uma tendência de superestimativa em torno de 100 mm.

### **2.2.2 Análise da distribuição geográfica da severidade da seca na região semiárida brasileira**

Com o intuito de obter mapas anuais que representam a distribuição das secas nessa região, utilizaram-se classes de índice de vegetação pela diferença normalizada (NDVI) e índice de seca pela diferença normalizada (NDDI), por meio da plataforma Google Earth Engine (Figura 5) e do Software QGIS (2.18).

Figura 5 - Fluxograma simplificado das etapas realizadas no Google Earth Engine e no Software livre QGIS versão 2.18



Fonte: Elaboração o autor.

O Google Earth Engine (GEE) consiste numa plataforma da web que utiliza uma grande capacidade computacional de armazenamento de dados de sensoriamento remoto em nuvem com um grande catálogo de imagens (GORELICK et al., 2017), possibilitando o processamento e a classificação de dados de sensoriamento remoto de forma rápida e em ambiente interativo, através de algoritmos (XIONG et al., 2017).

Foram utilizadas imagens MOD09A1 de 8 dias de resolução temporal obtidas através do sensor MODIS (Moderate Resolution Imaging Spectroradiometer), o qual está a bordo do satélite Terra (Figura 3). O produto MOD09A1 são imagens espectrais de superfície com 500 m de resolução espacial e com correção atmosférica para interferência de gases, aerossóis e espalhamento (VERMOTE et al., 2015). Após a adição das imagens MOD09A1, foram criados mosaicos anuais referentes ao período seco do ano, no período de 2008 a 2017. Inicialmente, foi gerado um algoritmo para adição da coleção de imagens MOD09A1 e, posteriormente, a geração do mosaico temporal referente a cada ano de avaliação.

Para a geração do mosaico anual, foi realizada a remoção das nuvens por um algoritmo que calcula a pontuação simples da probabilidade da presença de nuvem no intervalo de zero a cem, através da combinação de brilho, temperatura e NDSI (Índice de Neve pela Diferença Normalizada) em cada píxel. Após identificado o píxel que corresponde à nuvem, este foi

removido para dar lugar ao píxel da imagem posterior disponível, sendo então calculada a mediana dos pixels sem a presença de nuvens. Após a geração do mosaico anual da região semiárida, foram obtidos os índices espectrais de vegetação através de um algoritmo de álgebra de mapas criados no GEE (Tabela 1).

Tabela 1 - Índices espectrais de vegetação utilizados neste capítulo

Índice Espectral	Abreviação	Formula	Referência
Índice de Vegetação pela Diferença Normalizada	NDVI	$\frac{(\rho b2 - \rho b1)}{(\rho b2 + \rho b1)}$	Pearson & Miller, (1972)
Índice de Diferença Normalizada da Água	NDWI	$\frac{(\rho b2 - \rho b6)}{(\rho b2 + \rho b6)}$	Gao et al. (1996)
Índice de Seca pela Diferença Normalizada	NDDI	$\frac{NDVI - NDWI}{NDVI + NDWI}$	Gu et al. (2007)

Bandas espectrais MOD09A1:  $\rho b1$ - refletância de superfície do vermelho;  $\rho b2$ - refletância de superfície do infravermelho próximo,  $\rho b6$  - refletância de superfície do infravermelho de ondas curtas (SWIR1).

Após a geração dos mosaicos, foi calculado o NDVI que consiste na normalização da diferença das refletâncias das bandas do infravermelho próximo do vermelho (Tabela 1). O NDVI varia entre -1 e +1, de modo que quanto maior o valor do NDVI maior será a presença de vegetação. Porém, em alvos da superfície terrestre a tendência é que este índice varie entre 0,0 e 1,0, com menor presença de vegetação em valores próximos de 0,0 e maior presença da vegetação nos valores próximos de 1,0. Partindo deste princípio, foi aplicada a classificação de vigor da vegetação proposta por Aquino e Oliveira (2012), para verificar a variação temporal e espacial do vigor da vegetação no Semiárido brasileiro (classificação ilustrada na Tabela 2).

Para a obtenção da área correspondente à cada classe, os mapas de NDVI foram reclassificados com aplicação das classes de vigor da vegetação através do comando GRASS r.recode e, em sequência à reclassificação, o comando GRASS r.report presente no programa Qgis (versão 2.18), para obtenção do relatório das áreas correspondentes a cada classe (em km<sup>2</sup>). Também foi utilizado o índice de seca pela diferença normalizada (NDDI), com a finalidade de analisar a distribuição espacial e temporal das secas da região semiárida. O NDDI é um índice composto pela normalização do NDVI e do índice de umidade por diferença normalizada (NDWI, Tabela 1) e também foi obtido na plataforma GEE (Figura 3).

Tabela 2 - Descrição e intervalo das classes de NDVI para condição do vigor da vegetação da região semiárida brasileira

Classe	Critério de Classificação
Solo Exposto ou Agua	$NDVI \leq 0$
Vegetação Muito Baixa	$0 < NDVI \leq 0.2$
Vegetação Baixa	$0.2 < NDVI \leq 0.4$
Vegetação Moderamente Alta	$0.4 < NDVI \leq 0.6$
Vegetação Alta	$0.6 < NDVI \leq 0.8$
Vegetação Muito Alta	$0.8 < NDVI \leq 1$

Após calculado, o NDDI foi aplicado à classificação de indicadores de severidade de seca conforme as classes propostas por Gu et al. (2007). O NDDI é um indicador bastante sensível à seca, pois ele associa a informação de vigor da vegetação (NDVI) e de umidade local (NDWI) em sua equação (LEE et al., 2016). Altos valores de NDDI indicam condições de seca, logo tanto o NDVI e o NDWI são baixos (geralmente  $NDVI < 0,5$  e  $NDWI < 0,3$ ), porém valores baixos de NDDI indicam condições de ausência de seca, pois tanto o NDVI quanto o NDWI apresentam altos (geralmente  $NDVI > 0,6$  e  $NDWI > 0,4$ ) (GU et al., 2007).

Tabela 3 - Classificação dos indicadores de severidade de seca

<b>NDDI</b>	<b>Descrição</b>
$\leq - 0.49$	Ausência de seca
$- 0.49 \sim 1.99$	Seca anormal
$2.00 \sim 2.99$	Seca moderada
$3.00 \sim 3.99$	Seca severa
$4.00 \sim 4.99$	Seca extrema
$\geq 5.00$	Seca excepcional

Os mapas de NDDI foram reclassificados por meio do comando GRASS r.recode presente no Qgis (versão 2.18). As classes variam desde ausência de seca (valores de NDDI negativos) até seca excepcional, com valores maiores ou iguais a 5,0 (Tabela 3). Após a reclassificação foi aplicado o comando GRASS r.report do programa Qgis (versão 2.18) para obtenção do relatório de área (km<sup>2</sup>) correspondente à cada classe.

### 2.2.3 Distribuição dos rebanhos por municípios da região semiárida

Foi realizada uma análise da distribuição espacial e da variação temporal dos rebanhos da região semiárida através de dados do IBGE, obtidos via SIDRA (Sistema IBGE de Recuperação Automática), no período de 2008 a 2017. As informações foram obtidas no site do IBGE (<https://sidra.ibge.gov.br/pesquisa/ppm/tabelas>), onde consta o levantamento municipal de efetivos dos rebanhos de animais por espécie animal.

No SIDRA foram obtidos dados referentes à população de caprinos, ovinos e bovinos de



todos os municípios integrantes da região semiárida brasileira. Para a construção dos mapas foi utilizado o programa Qgis (versão 2.18). Inicialmente, foi necessária a inclusão dos dados referentes ao geocódigo de todos os municípios pertencentes à região semiárida. O geocódigo consiste numa identificação numérica que cada município brasileiro recebe pelo IBGE, com o intuito de facilitar a mescla de dados de diferentes fontes. A partir do geocódigo juntou-se a base de dados obtidos no SIDRA com a base de dados do shape (shp.) dos municípios utilizando a ferramenta junção de tabelas do Qgis. A partir do pareamento das informações foram construídos mapas temáticos da distribuição da populacional dos rebanhos, bem como foi feito um comparativo das duas séries históricas com relação ao aumento ou à redução da população em termos percentuais.

#### **2.2.4 Análises estatísticas e correlação de Spearman entre precipitação e os índices espectrais de vegetação**

Os dados obtidos durante os 10 anos de estudo foram divididos em duas séries históricas para fim de comparação estatística. Foi utilizado o Teste t pareado com um nível de significância de 10% ( $P < 0,10$ ) por meio do procedimento `proc ttest` do ‘*software*’ SAS versão SAS University Edition. A escolha do Teste T pareado para comparação das séries históricas foi devido ao presente estudo realizar a comparação do antes e o depois da região semiárida brasileira temporalmente, portanto, possuir observações emparelhadas. Foi feita análise de regressão linear dos dados dos rebanhos ao longo do período de estudo (2008-2017) em relação à % do rebanho nacional e em animais por  $\text{km}^2$ , para verificar qual mudança temporal foi mais significativa por meio do coeficiente de inclinação da equação.

Para fim de analisar a correlação da precipitação CHIRPS com os índices espectrais de vegetação, utilizaram-se os dados colhidos nos 160 pontos criados nas unidades de conservação. Inicialmente, foi analisada a normalidade dos dados, que não foi confirmada. Dessa forma, adotou-se a correlação de Spearman por meio do pacote `CorrPlot` (WEI et al., 2017) do Software R Studio, o qual também foi utilizado para a plotagem da matriz de correlação. Para a representação numérica da variação temporal dos dados, foram utilizados métodos gráficos, com auxílio do programa Sigma Plot (versão 11.0).

### **2.3 Resultados E Discussão**

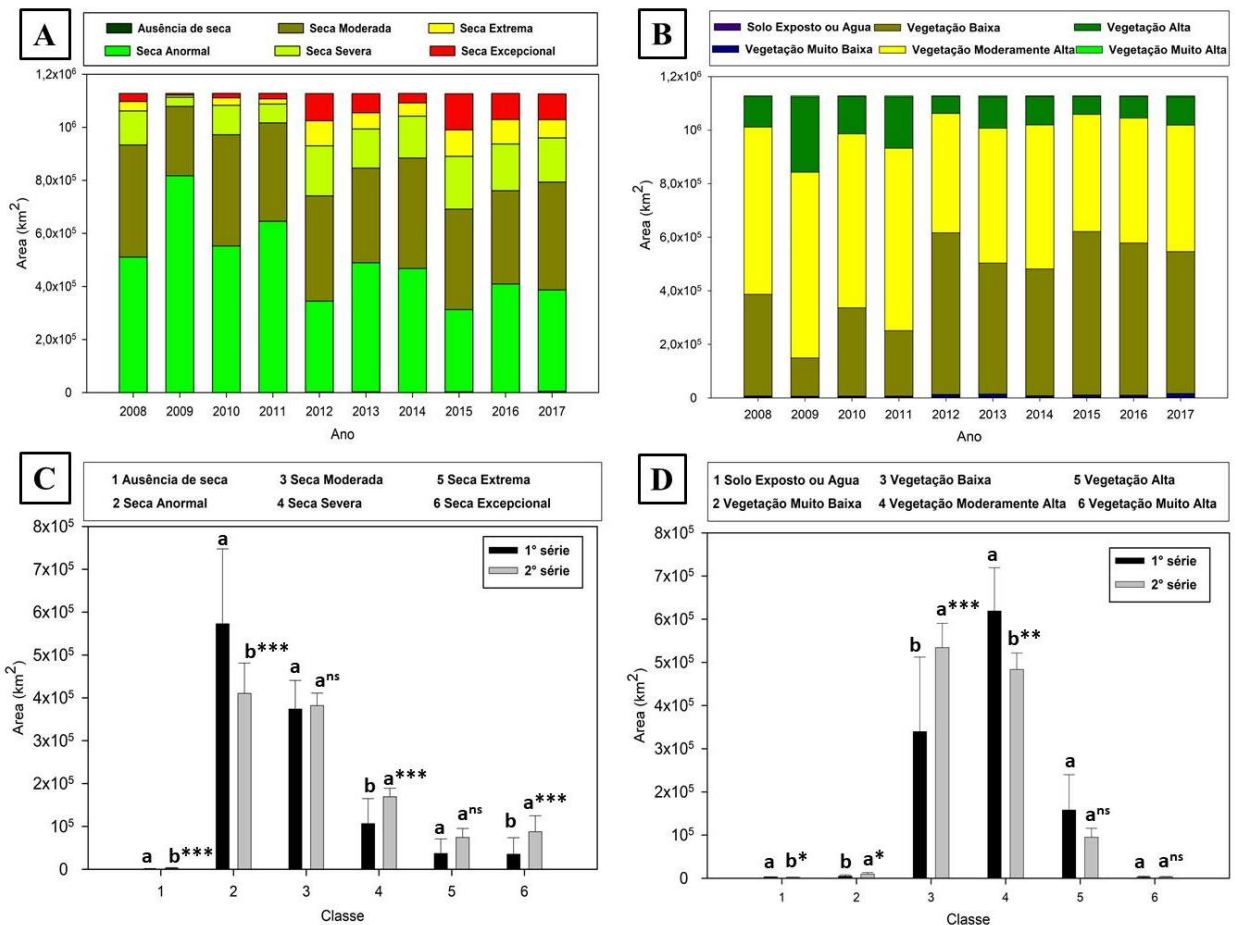
#### **2.3.1 Distribuição das secas na região semiárida com dados MOD09A1 (2008-2017)**

Os resultados sugerem variação interanual do NDDI (Figura 6A) e das classes de vigor

da vegetação (Figura 6B). Possivelmente, a variação ocorreu pelas oscilações das precipitações interanuais (Figura 4B), que é uma característica importante da região semiárida brasileira e afeta diretamente as incidências de secas e o vigor da vegetação. A análise estatística comparativa das duas séries históricas por meio do Teste T pareado observou-se que as classes seca moderada e seca extrema não apresentaram diferença ( $P>0.10$ ), enquanto seca extrema ( $P=0.0849$ ) e seca excepcional ( $P=0.0705$ ) apresentaram a maior área na 2ª série histórica, enquanto que seca anormal ( $P=0.0910$ ) apresentou maior área na 1ª série histórica.

No comparativo das duas séries históricas na classe de vigor da vegetação, notou-se que vegetação alta e muito alta não apresentaram diferença ( $P>0.10$ ), enquanto solo exposto ou água ( $P=0.0038$ ), vegetação muito baixa ( $P=0.0376$ ) e vegetação baixa ( $P=0.0674$ ) tiveram maiores áreas referentes à 2ª série histórica, enquanto para vegetação moderadamente alta ( $P=0.0177$ ), as maiores áreas foram obtidas na 1ª série histórica.

Figura 6 - Variação e comparação estatística das classes de indicadores de severidade de seca (A-C) e de vigor da vegetação NDVI (B-D). Valores com letras distintas dentro da mesma classe diferem entre si pelo teste T pareado. \* $P<0.01$ ; \*\* $P<0.05$ ; \*\*\* $P<0.10$ ; <sup>NS</sup> $P>0,10$

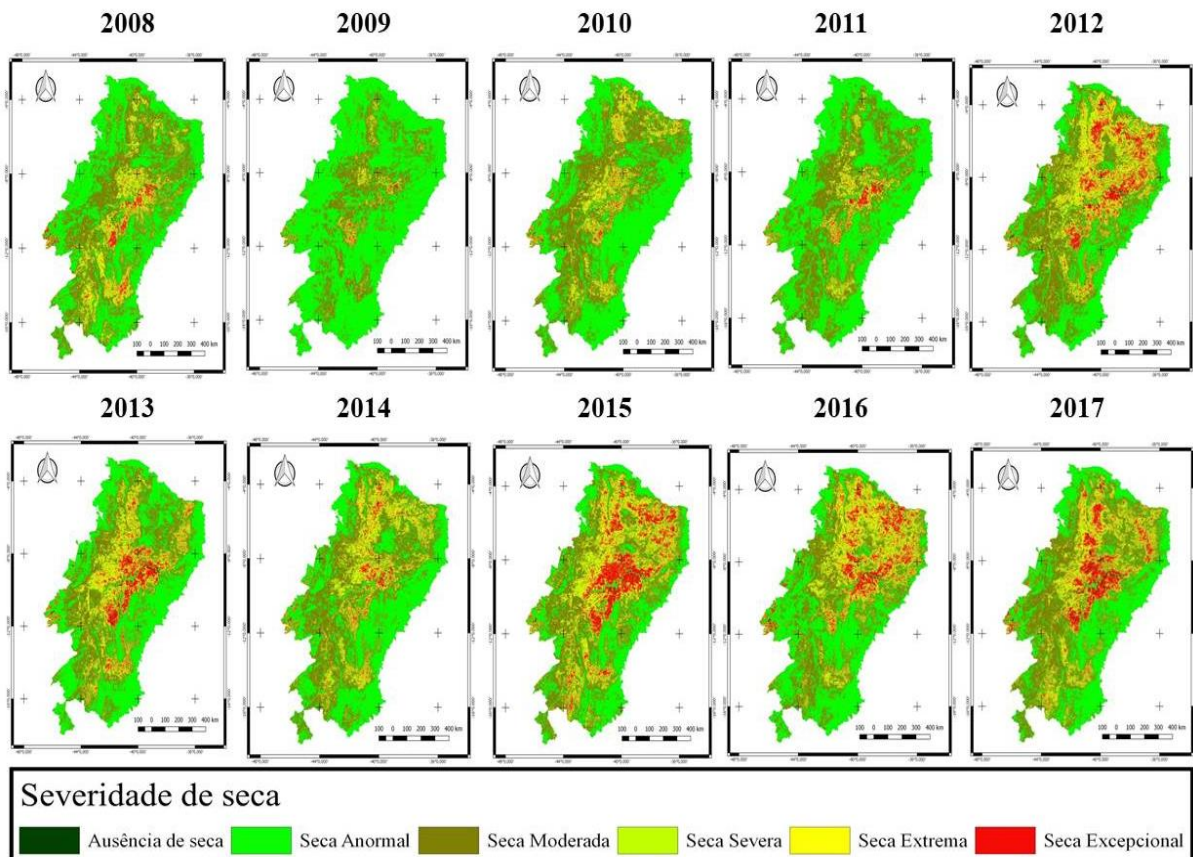


Fonte: Elaboração do autor.

As precipitações na região semiárida brasileira variam no espaço e tempo (MUIR et al., 2019) e o seu comportamento afeta diretamente a incidência de secas. Segundo Marengo et al. (2018), as secas da região semiárida são causadas por efeito do El Niño e pela variação da temperatura superficial do Atlântico Norte, e nos últimos anos ocorreram de forma extrema, com impacto direto sobre a economia local. Além disso, as mudanças climáticas têm influenciado diretamente nos regimes de precipitação e na ocorrência de secas, sabendo que a mudança climática tem sido atribuída a processos de emissão de gases por ações naturais e/ou antrópicas, causando alterações no balanço de energia, aumento de temperaturas e evaporação, modificando o ciclo das chuvas e diminuindo a umidade dos solos (RUFINO & SILVA, 2017).

Foi possível verificar através do mapa da distribuição geográfica das classes de severidade de seca (Figura 7) onde são mais intensas e frequentes. Analisando geograficamente, pode-se inferir que existem municípios mais afetados do que outros, pois apresentaram vermelho ou amarelo em anos seguidos, destacando os municípios da região central do Semiárido durante os anos de 2015, 2016 e 2017. Logo, possivelmente a pecuária destas regiões podem ter sido mais afetadas pelo efeito aditivo de anos seguidos de secas numa mesma região.

Figura 7 - Mapas da distribuição das classes de indicadores de seca palmer na região do Semiárido brasileiro a partir de dados MOD09A1



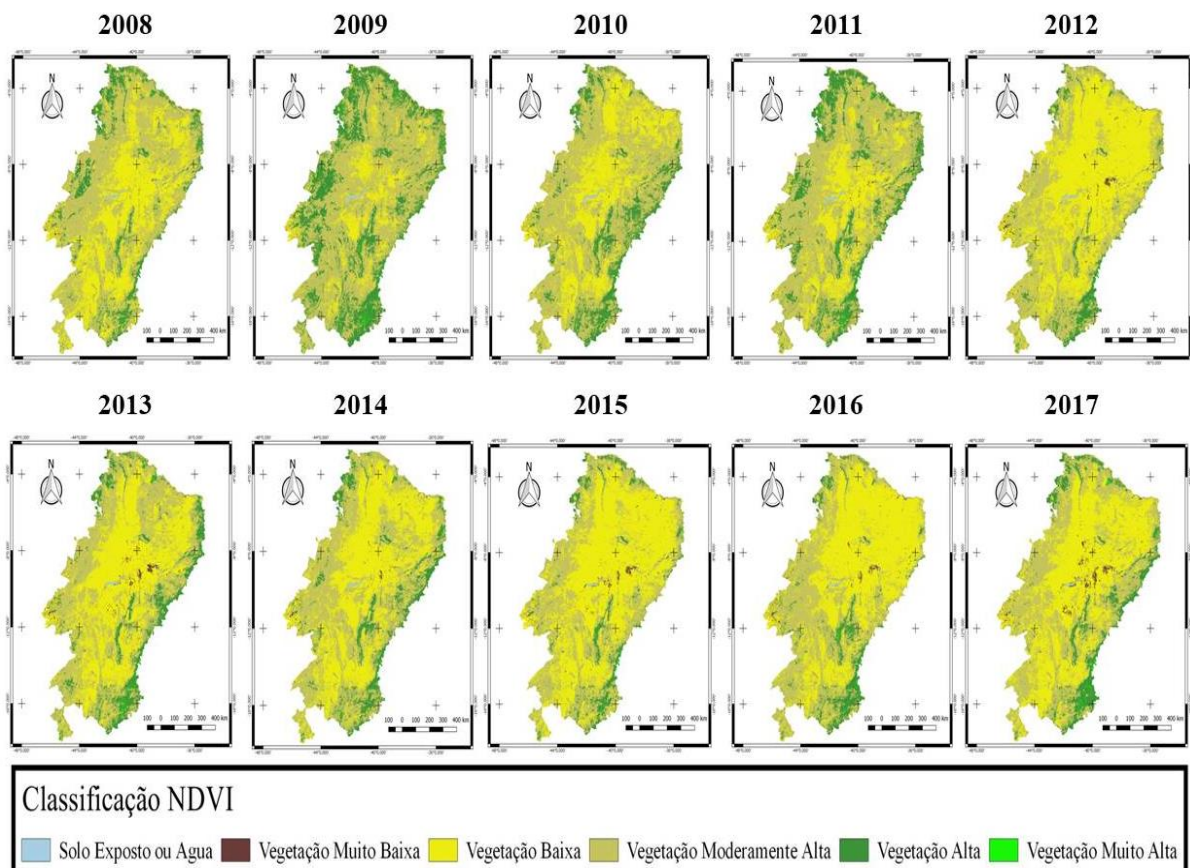
Fonte: Elaboração o autor.

Segundo Tavazohi & Nadoushan (2018), a informação da dinâmica da vegetação é muito importante para a realização do monitoramento de secas e pode auxiliar no planejamento, acompanhamento, previsões e assistências às zonas mais afetadas, servindo como indicativos para estimar informações de precipitação, umidade do solo ou abastecimento de água de um determinado local. Estas características têm tornado útil o NDDI para monitoramento de áreas susceptíveis as secas (LEE et al., 2016).

Gu et al. (2007) analisaram a capacidade do índice de seca pela diferença normalizada (NDDI) em monitorar pastagens na região de Flint Hills nos Estados Unidos através de dados MODIS e concluíram que o NDDI demonstrou ser um importante indicador para o monitoramento das secas numa escala regional, porém é necessária uma ampliação dos estudos do NDDI como uma ferramenta de monitoramento de secas aplicada a uma maior

diversidade de vegetações. Nota-se, por meio da distribuição geográfica das classes de vigor da vegetação com base no NDVI (Figura 8), que as vegetações mais densas como estão mais localizadas nas bordas do semiárido, justamente nas regiões em que a predominância da vegetação é Mata Atlântica e Cerrado. Os mapas de NDVI indicam as regiões com vegetação mais abundante, de modo que se sugere que nestas regiões há uma maior oferta de forragem para alimentar os rebanhos e, conseqüentemente, menor será a probabilidade de que os pecuaristas tenham perdas por falta de alimento forrageiro.

Figura 8 - Mapas temáticos de classes de vigor da vegetação com base no NDVI obtidos por imagens MOD09A1 para a região do Semiárido brasileiro



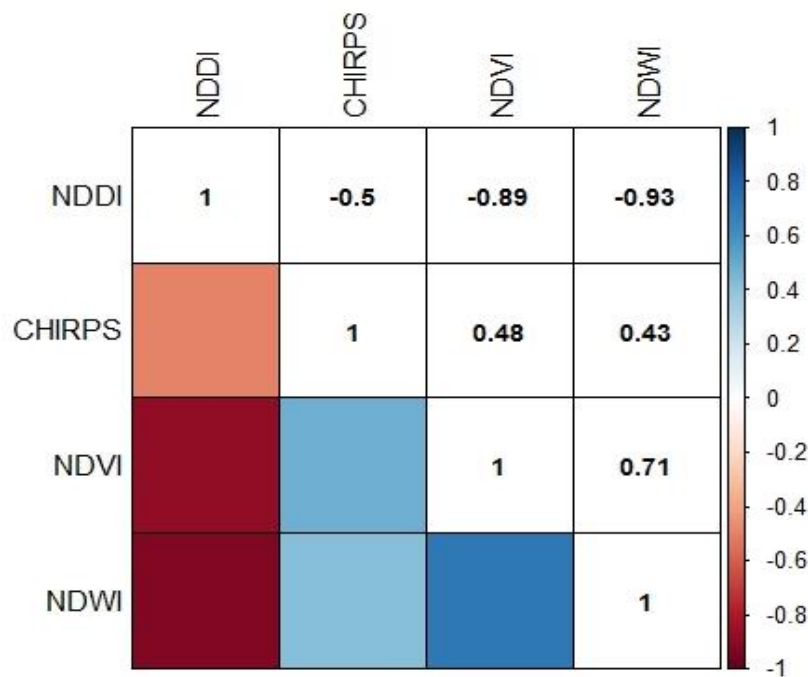
Fonte: Elaboração pelo autor.

O NDVI é um dos índices espectrais mais utilizados para realização de análises e estudos de vegetações (HOTT et al., 2016; VRIELING et al., 2011). Este índice se baseia no princípio de que o comprimento de onda na banda do vermelho é quase totalmente absorvido por superfícies vegetais ricas em biomassa verde e fotossinteticamente ativa, enquanto a banda do infravermelho é refletida (MYNENI et al., 1995). Aquino et al., (2018) realizaram uma análise na variação de classes de vigor da vegetação com base no NDVI de 1985-2011

no município de Tauá (município pertencente ao Semiárido brasileiro) e associaram as variações nesse índice à precipitação, uma vez que a vegetação de Caatinga apresenta uma resposta rápida aos anos de maior precipitação.

A correlação entre o NDDI e a precipitação CHIRPS foi moderada e negativa ( $r=-0.5$ ,  $P<0.01$ ), e os índices NDVI ( $r=0.48$ ,  $P<0.01$ ) e NDWI ( $r=0.43$ ,  $P<0.01$ ) apresentaram fraca correlação positiva com a precipitação CHIRPS (Figura 9). Os índices apresentaram alta correlação entre si. Apesar de serem diferentes índices, todos possuem a premissa básica de que à medida que ocorrem alterações morfológicas no dossel da vegetação, também ocorrem variações nas frações absorvidas, transmitidas e refletidas da radiação solar incidente.

Figura 9 - Correlação de Spearman entre a precipitação CHIRPS e os índices espectrais de vegetação utilizados no presente estudo



Fonte. Elaboração do autor.

Além disso, é importante destacar que a produção de biomassa tem alta relação com a presença de umidade, o que justifica a alta correlação entre o NDVI e o NDWI. No entanto, os índices espectrais de vegetação apresentam média correlação com a precipitação estimada pelo produto CHIRPS, o que pode ser explicada pela grande variação estrutural das vegetações monitoradas ao longo do semiárido que mesmo sendo regiões de unidades de conservação, apresentam diferenças estruturais, bem como os dados CHIRPS terem um histórico de superestimativa da precipitação.

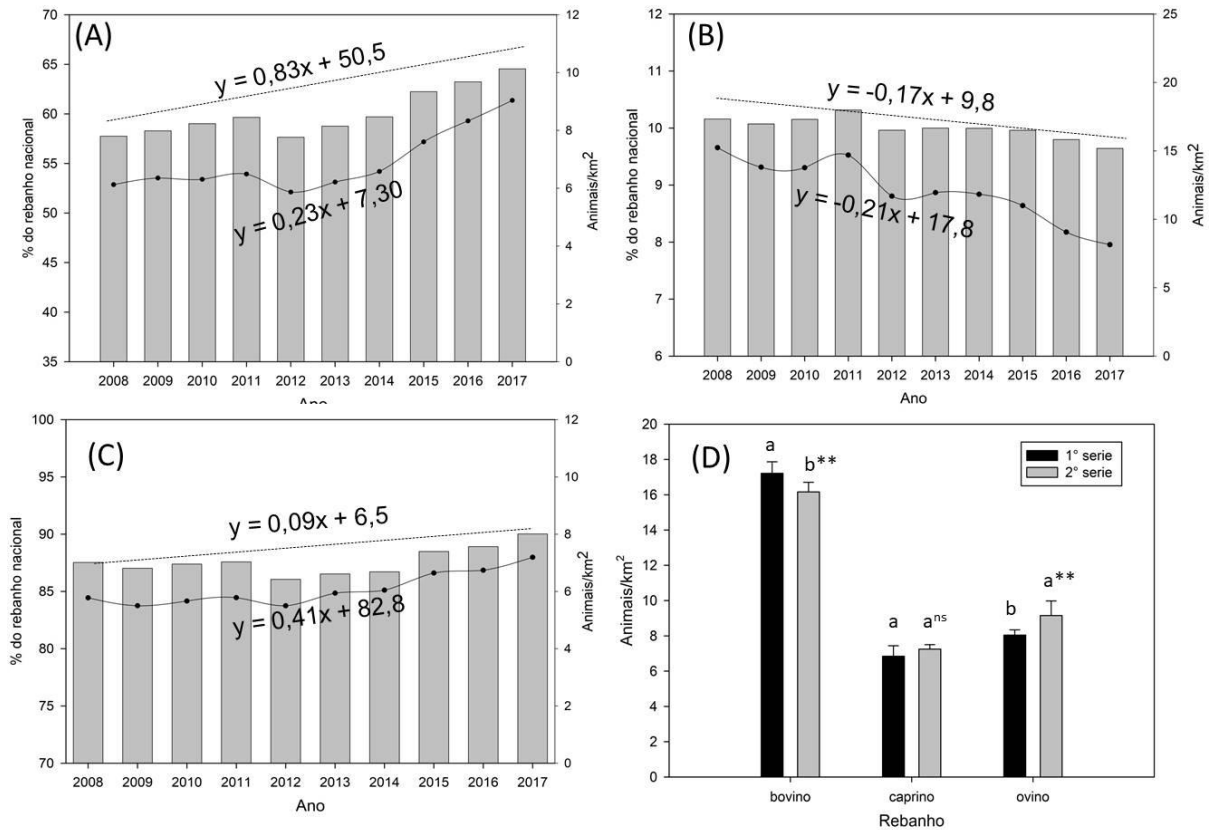


Como já descrito, a vegetação predominante da região semiárida é a Caatinga, que é constituída especialmente de espécies herbáceas, arbustivas e arbóreas de pequeno porte, sendo que uma característica importante das plantas desta vegetação é a caducifolia, em que as plantas perdem suas folhas na estação seca para evitar perdas por transpiração. Com isso, há uma alteração no teor de clorofila da vegetação causada pelo estresse hídrico (CECCATO et al., 2001) e essa combinação de informações de refletância do vermelho, infravermelho e infravermelho de ondas curtas podem ter sido úteis para o monitoramento da condição de seca na região.

### 2.3.2 Mudança e distribuição dos rebanhos da região semiárida brasileira

Observou-se redução do rebanho bovino e aumento no rebanho caprino e ovino ao longo do período de estudo (Figura 10). Notou-se aumento do rebanho caprino e ovino (de 2008 para 2017) com relação ao rebanho nacional na ordem de 3,03% para caprinos e 8,5% para ovinos (Figura 10A e C, respectivamente), enquanto houve uma redução do rebanho bovino de 17,33% caindo para 15,17% com relação ao rebanho nacional, havendo uma redução de 2,16% (Figura 10B), sendo verificado uma inclinação negativa mais acentuada quando foi analisado animais/km<sup>2</sup> ( $\beta_1=-0,21$ ).

Figura 10 - Descrição da variação populacional dos rebanhos de ovinos (A), bovinos (B) e caprinos (C) expressos em % do rebanho nacional (barras verticais) e em animais/km<sup>2</sup> no Semiárido brasileiro (linhas), e comparação estatística da 1° e 2° séries históricas por meio do teste T pareado (D). Valores com letras distintas dentro da mesma classe diferem entre si pelo teste T pareado. \*P< 0.01; \*\*P<0.05; \*\*\*P<0.10; <sup>NS</sup>P>0,10



Fonte: Elaborado pelo autor.

O rebanho bovino reduziu 2,16% e 1,7 animais/km<sup>2</sup>, enquanto o rebanho caprino aumentou 3,03% e 1 animais/km<sup>2</sup>. O rebanho ovino foi o que apresentou aumento mais expressivo, na ordem de 8,5% que corresponde a 2,33 animais/km<sup>2</sup>. Analisando os coeficientes de inclinação da equação referente aos ovinos, notou-se uma inclinação positiva e mais acentuada quando foi analisado em relação à % do rebanho nacional ( $\beta_1=0,83$ ) quando comparado a animais/km<sup>2</sup> ( $\beta_1=0,23$ ), enquanto a equação referente aos caprinos foi mais acentuada na análise de animais/km<sup>2</sup> ( $\beta_1=0,41$ ) com coeficiente positivo.

Mesmo havendo aumento do rebanho caprino, a análise estatística comparativa das séries históricas pelo Teste T pareado mostrou que não houve diferença estatística ( $P>0,10$ ) das duas séries históricas (Figura 10D). O rebanho bovino apresentou redução ( $P=0,0303$ ) da 1<sup>o</sup> para a 2<sup>o</sup> série histórica e o rebanho ovino aumento ( $P=0,0365$ ).

Segundo Barbosa et al. (2019), durante os anos de 2012 a 2015 ocorreram secas intensas no Semiárido brasileiro e estas trouxeram impactos jamais vistos antes nesta região, estimando-se perdas de até 6 bilhões de dólares. Para Angelotti et al., (2011), a região semiárida brasileira será uma das regiões mais afetadas pelas mudanças climáticas, pois, além dos cenários de aumentos de temperatura, esta região possui tendência de se tornar mais árida, podendo ocorrer um aumento na frequência e na intensidade das secas e consequente redução

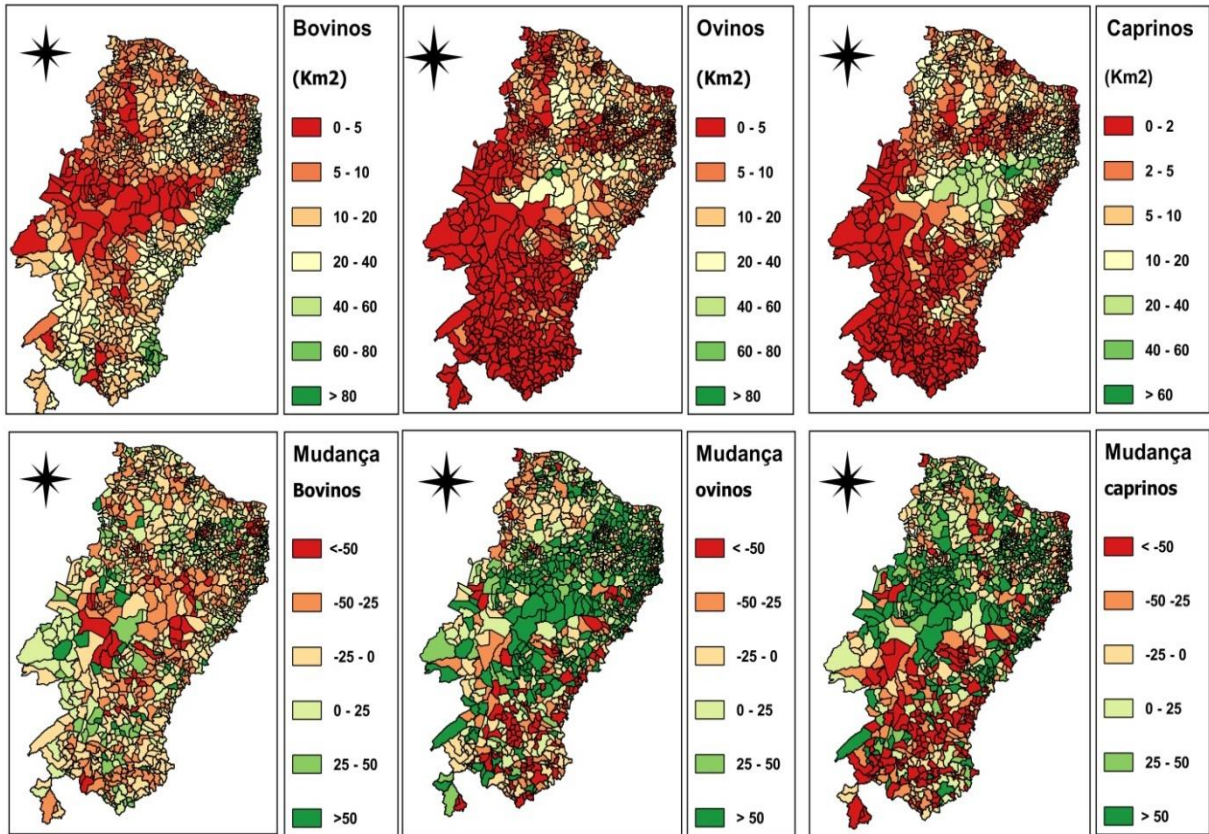


na disponibilidade de recursos hídricos.

Logo, as variações extremas nas temperaturas e nos padrões de precipitação ocasionam impactos diretos na atividade pecuária, principalmente devido ao comportamento da precipitação interferir diretamente no vigor da vegetação (HERMANCE et al., 2015) e, conseqüentemente, na oferta de forragem aos rebanhos (SAYRE et al., 2013). Segundo Nogueira et al. (2010), a instabilidade dos regimes de precipitação da região semiárida é uma das principais causas da estacionalidade da produção dos rebanhos, interferindo diretamente na produção pecuária local, principalmente por comprometer a oferta de forragem para os animais. Mesmo que pouco produtiva, a pecuária na região semiárida tem sido opção com relação à agricultura, pois as culturas são mais afetadas pela falta de chuvas em períodos críticos de crescimento, levando os donos de propriedades a optarem pela pecuária por ser menos sensível à escassez hídrica (COUTINHO et al. 2013).

Os mapas da distribuição dos rebanhos (animais/km<sup>2</sup>) e da mudança (%) dos rebanhos bovinos, caprinos e ovinos (Figura 11) sugerem a possibilidade de verificar a distribuição geográfica de redução ou aumento do efetivo de rebanho. Relacionando os mapas da Figura 11 com os mapas das Figuras 7 e 8, nota-se que as regiões onde as secas foram mais intensas concentram geograficamente os municípios com aumento do rebanho efetivo de ovinos e caprinos.

Figura 11 - Mapas da distribuição geográfica e mudança temporal dos rebanhos bovinos, caprinos e ovinos (animais/km<sup>2</sup>) da região do Semiárido brasileiro por meio do processamento de dados do Sidra/IBGE.



Fonte: Elaborado pelo autor.

Importante destacar que houve redução do rebanho bovino e aumento do ovino quando foi analisada a região semiárida, porém este comportamento foi diferente considerando os diferentes municípios da região, indicando que, mesmo sendo municípios pertencentes ao semiárido, a seca afetou mais intensamente algumas regiões em detrimento de outras.

O aumento de ovinos e de caprinos muito possivelmente ocorreu devido a estas espécies possuírem diferentes mecanismos de adaptação a ambientes secos. Sabe-se que a criação de ovinos e caprinos tem grande identidade com a região semiárida e vem sendo reconhecida como importante atividade econômica para a região, demandando atenção especial para se tornar cada vez mais competitiva. Segundo Otaviano (2020), os pequenos ruminantes são espécies consideradas mais viáveis para serem criadas em regiões com vulnerabilidade climática, pois apresentam maior versatilidade em compor a sua dieta nos períodos de adversidade do que outros animais, principalmente pela alta capacidade seletiva, onde num ambiente com alta variação na disponibilidade de forragem entre os estratos herbáceo e

lenhoso, como a Caatinga, os pequenos ruminantes conseguem explorar com mais eficiência a vegetação.

Somado a isso, algumas características fisiológicas que os pequenos ruminantes possuem como a maior facilidade de dissipação de calor por serem animais de menor tamanho corporal, somado as características de suas fezes serem mais secas (ARAÚJO FILHO, 2006), promovem menor desidratação quando comparadas às de bovinos, fazendo com que os pequenos ruminantes possam explorar melhor ambientes secos. Além disso, outra explicação possível para este comportamento dos rebanhos é uma tendência de mudança no perfil dos sistemas de produção da região semiárida. Com o avançar dos períodos de seca houve a necessidade da adoção de sistemas mais intensivos e, conseqüentemente, a permanência e a seleção dos animais de alto potencial produtivo na fazenda, sabendo que os ovinos são mais adaptados a este sistema de produção em detrimento ao caprino, que é mais explorado em condições meramente extensivas.

A aplicação do geoprocessamento é uma ferramenta útil em pesquisas na área da pecuária, podendo caracterizar e demonstrar os diversos sistemas de produção animal através de produtos cartográficos (ROBINSON et al., 2011). Além disso, o conhecimento da estrutura e da distribuição geográfica por meio do mapeamento da pecuária permite a definição de políticas de infraestrutura, transporte, logística, análise de viabilidade de projetos de desenvolvimento regional e setorial, e estudos da dinâmica do setor agropecuário (ZOCCAL et al., 2006). Buggenhout (2008) realizou uma análise da distribuição geográfica do rebanho bovino do Brasil por geoprocessamento de dados do IBGE. Os resultados levaram o autor a concluir que o aumento do rebanho bovino nas regiões Centro-Oeste e Norte e redução nas regiões Sul e Sudeste sugerem uma migração da criação pecuária bovina para a região Centro-Oeste e Norte. A partir desta análise, pode-se destinar enfoque de investimentos e apoios às regiões com maior demanda de planejamento com uma base ambiental, econômica e sanitária.

## **2.4 CONCLUSÃO**

O uso de dados de sensoriamento remoto aplicados a fenômenos naturais é útil na geração de produtos cartográficos como a distribuição regional das secas. Com a produção de mapas indicando os locais mais afetados pelas secas, torna-se possível destinar benefícios como políticas de apoio e de convívio com a seca para estas regiões, de modo que suas populações possam se antecipar à ocorrência de desastres.

Os resultados encontrados neste estudo consideram alta a capacidade dos índices NDDI e NDVI em monitorar a distribuição das secas no Semiárido brasileiro, uma vez que as

vegetações presentes nesta região são sensíveis às refletâncias do vermelho, infravermelho próximo e infravermelho de ondas curtas.

O geoprocessamento de dados SIDRA/IBGE possibilitou uma análise da distribuição espacial e da variação temporal dos rebanhos da região semiárida e esta análise gerou informações acerca dos locais de maior crescimento da criação de ovinos e caprinos frente aos riscos de períodos de incertezas climáticas.

## REFERÊNCIAS

- AB'SÁBER, Aziz Nacib. **Os domínios de natureza no Brasil: potencialidades paisagísticas**. Ateliê editorial, 2003.
- ALBUQUERQUE, Ulysses Paulino de; MELO, Felipe PL. Socioecologia da Caatinga. **Ciência e Cultura**, Campinas, v. 70, n. 4, p. 40-44, 2018.
- ANGELOTTI, Francislene; FERNANDES JÚNIOR, P. I.; SA, IB de. Mudanças Climáticas no Semiárido Brasileiro: Medidas de Mitigação e Adaptação. **Revista Brasileira de Geografia Física**, Recife, v. 4, p. 1097-1111, 2011.
- AQUINO, Cláudia Maria Sabóia; OLIVEIRA, José Gerardo Beserra. Estudo da dinâmica do Índice de Vegetação por Diferença Normalizada (NDVI) no núcleo de São Raimundo Nonato-PI. **GEOUSP - Espaço e Tempo**, São Paulo, v. 16, n. 2, p. 157-168, 2012.
- AQUINO, Deodato do Nascimento et al. Use of remote sensing to identify areas at risk of degradation in the semi-arid region. **Revista Ciência Agronômica**, Fortaleza, v. 49, n. 3, p. 420-429, 2018.
- ARAUJO FILHO, João Ambrosio de. **Manejo pastoril sustentável da caatinga**. vol. 01, Cidade Gráfica e Editora Ltda., pp. 200, 2013.
- ARAUJO FILHO, João Ambrosio de. Aspectos zo ecológicos e agropecuários do caprino e do ovino nas regiões semi-áridas. **Embrapa Caprinos e Ovinos-Documents (INFOTECA-E)**, 2006.
- BAJGAIN, Rajen et al. Sensitivity analysis of vegetation indices to drought over two tallgrass prairie sites. **ISPRS Journal of Photogrammetry and remote Sensing**, Amsterdam, v. 108, p. 151-160, 2015.
- BARBOSA, Humberto Alves et al. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008-2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 1, n. 2, p. 1-18, 2019.
- BRASIL. Ministério do Meio Ambiente - MMA. Disponível em: <http://www.mma.gov.br>. Acesso em: 12 out. 2019.
- BUGGENHOUT, Erik Rodrigues Backx Van. **Análise multivariada de dados do censo agropecuário e distribuição espacial dos rebanhos bovinos**. 2008, pag. 51, Monografia, Departamento de Geografia. Brasília, Universidade de Brasília.
- CECCATO, Pietro et al. Detecting vegetation leaf water content using reflectance in the optical domain. **Remote sensing of environment**, Amsterdam, v. 77, n. 1, p. 22-33, 2001.
- COSTA, R. G. et al. Caracterização do sistema de produção caprino e ovino na região Semiárida do estado da Paraíba. Brasil. **Archivos de Zootecnia**, Cordoba, v. 57, n. 218, pp. 195-205, 2008.
- COSTA, Julio Cezar et al. Validação dos dados de precipitação estimados pelo CHIRPS para

o brasil. **Revista Brasileira de Climatologia**, Curitiba, v. 24, n.1 p. 228-243, 2019.

EDVAN, Ricardo Loiola; PINTO, Andréa Pereira. Pecuária como atividade estabilizadora no semiárido brasileiro. **Veterinária e Zootecnia**, Botucatu, v. 13, p. 9, 2013.

DA SILVA, Marisa Maria Venâncio et al. Desafios e paradigmas de convivência com a seca no semiárido. **Biodiversidade, Etnoconhecimento e Produção Sustentável**. Ananindeua: Itacaiúnas, p. 93, 2020.

FERREIRA, Laerte Guimarães; FERREIRA, Nilson Clementino; FERREIRA, Manuel Eduardo. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, Maringa, v. 30, n. 4, p. 379-390, 2008.

FUNK, Chris et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific data**, v. 2, n. 1, p. 1-21, 2015.

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, Amsterdam, v. 58, n. 3, p. 257-266, 1996.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, Amsterdam, v. 202, p. 18–27, 2017.

GU, Yingxin et al. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, Washington, v. 34, p. 1-6, 2007.

HE, Chunyang et al. Zoning grassland protection area using remote sensing and cellular automata modeling - A case study in Xilingol steppe grassland in northern China. **Journal of Arid Environments**, Londres, v. 63, n. 4, p. 814-826, 2005.

HERMANCE, John F.; AUGUSTINE, David J.; DERNER, Justin D. Quantifying characteristic growth dynamics in a semi-arid grassland ecosystem by predicting short-term NDVI phenology from daily rainfall: a simple four parameter coupled-reservoir model. **International Journal of Remote Sensing**, Abingdon, v. 36, n. 22, p. 5637-5663, 2015.

HOTT, Marcos Cicarini et al. Vegetative growth of grasslands based on hyper-temporal NDVI data from the Modis sensor. **Pesquisa Agropecuária Brasileira**, Brasília, v. 51, n. 7, p. 858-868, 2016.

LEE, Soo-Jin et al. On the relationships between satellite-based drought index and gross primary production in the North Korean croplands, 2000–2012. **Remote Sensing Letters**, v. 7, n. 8, p. 790-799, 2016.

LU, Dengsheng et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, Londres, v. 9, n. 1, p. 63-105, 2016.

MAIA, Stoécio Malta Ferreira et al. Organic carbon pools in a Luvisol under agroforestry and conventional farming systems in the semi-arid region of Ceará, Brazil. **Agroforestry systems**,

Amsterdam, v. 71, n. 2, p. 127-138, 2007.

MARENGO, José A. et al. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 90, n. 2, p. 1973-1985, 2018.

MENDES, S. et al. Remote sensing and GIS combination to evaluate the ecosystems' conditions in "Serras do Porto". In: **Remote Sensing for Agriculture, Ecosystems, and Hydrology XX**. Bellingham, International Society for Optics and Photonics, 2018. p. 107832E.

MUIR, James Pierre et al. Value of endemic legumes for livestock production on Caatinga rangelands. **Revista Brasileira de Ciências Agrárias**, Recife, v. 14, n. 2, 2019.

MYNENI, Ranga B. et al. The interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, Pasadena, v. 33, n. 2, p. 481-486, 1995.

OTAVIANO, Emanoella Karol Saraiva. **Composição botânica da dieta e índice de seletividade de pequenos ruminantes em pastejo no semiárido brasileiro**. Dissertação de Mestrado, Departamento de Zootecnia, Fortaleza, Universidade Federal do Ceará. pag. 46, 2020.

NOGUEIRA, Narjara Walessa et al. Alternativas alimentares para ovinos e caprinos no semiárido brasileiro. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, Pombal, v. 5, n. 2, p. 5-12, 2010.

PAREDES-TREJO, Franklin J.; BARBOSA, H. A.; KUMAR, TV Lakshmi. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of arid environments**, Londres, v. 139, p. 26-40, 2017.

PEARSON, Robert Lawrence; MILLER, Lee Durward. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie. v. rse, p. 1355, 1972.

SILVA, Aderbal Marcos de Azevedo et al. Manejo da Caatinga para produção de caprinos e ovinos. **Revista Brasileira de Saúde e Produção Animal**, Salvador, v. 14, n. 1, p. 77-90, 2013.

PINHEIRO, Felipe M.; NAIR, PK Ramachandran. Silvopasture in the Caatinga biome of Brazil: A review of its ecology, management, and development opportunities. **Forest Systems**, Madrid, v. 27, n. 1, p. 1-16, 2019.

RENZA, Diego et al. Drought estimation maps by means of multirate Landsat fused images. In: **Proceedings of the 30th EARSeL Symposium**. 2010.

ROBINSON, Timothy P. et al. Mapping the Global Distribution of Livestock. **PLoS ONE**, San Francisco, v. 9, n. 5, p. 232-240, 2014.

ROBINSON, Timothy P. et al. **Global livestock production systems**. Rome, Food and Agriculture Organization of the United Nations (FAO) and International Livestock Research Institute (ILRI), 152 pp, 2011.

- RUFINO, Iana Alexandra Alves; SILVA, Simone Tavares da. Análise das relações entre dinâmica populacional, clima e vetores de mudança no semiárido brasileiro: Uma abordagem metodológica. **Boletim de Ciências Geodésicas**, Curitiba, v. 23, n. 1, p. 166-181, 2017.
- SAYRE, Nathan F. et al. Earth stewardship of rangelands: coping with ecological, economic, and political marginality. **Frontiers in Ecology and the Environment**, Washington, v. 11, n. 7, p. 348-354, 2013.
- SHAHABFAR, A.; EITZINGER, J. Agricultural drought monitoring in semi-arid and arid areas using MODIS data. **The Journal of Agricultural Science**, Cambridge. v. 149, n. 4, p. 403-414, 2011.
- TAVAZOHI, Elena; AHMADI, M. Assessment Of Drought In The Zayandehroud Basin During 2000–2015 Using Nddi And Spi Indices. **Fresenius Environmental Bulletin**, v. 27, n. 4, p. 2332-2340, 2018.
- THORNTON, Philip K. et al. Vulnerability, Climate Change and Livestock– Res. Opportunities and Challenges for Poverty Alleviation, ICRISAT Int. **Livestock Res. Inst.**, v. 4, n. 1, pp 21–32,. 2007.
- VERMOTE, E. F.; KOTCHENOVA, S. Y.; RAY, J. P. MODIS Land surface reflectance science computing facility. **MODIS Surface Reflectance User’s Guide**; version, v. 1, 2011.
- VRIELING, Anton; DE BEURS, Kirsten M.; BROWN, Molly E. Variability of African farming systems from phenological analysis of NDVI time series. **Climatic change**, Berlin, v. 109, n. 3-4, p. 455-477, 2011.
- WARREN, Georgina; METTERNICHT, Graciela. Agricultural applications of high-resolution digital multispectral imagery. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 71, n. 5, p. 595-602, 2005.
- WEI, Taiyun et al. Package ‘corrplot’. *Statistician*, v. 56, n. 316, p. e24, 2017.
- XIONG, Jun et al. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 126, p. 225-244, 2017.
- ZHAO, Peisheng; FOERSTER, Theodor; YUE, Peng. The geoprocessing web. **Computers & Geosciences**, v. 47, p. 3-12, 2012.
- ZOCCAL, Rosangela; ASSIS, Airdem Gonçalves de; EVANGELISTA, Silvio Roberto de Medeiros. Distribuição geográfica da pecuária leiteira no Brasil. **Revista de Política Agrícola**, Brasília, v. 15, n. 4, p. 47-58, 2006.



### **3 CAPÍTULO II: CARACTERIZAÇÃO ESPECTRAL DE FRAGMENTOS DE PASTAGEM NATIVA E MUDANÇA DO USO E OCUPAÇÃO DO SOLO EM REGIÕES DO BIOMA CAATINGA**

#### **RESUMO**

O objetivo deste estudo foi caracterizar o comportamento espectral, avaliando a sazonalidade do fator de refletância bidirecional de superfície (FRBS) e dos índices espectrais de vegetação de fragmentos de pastagens nativas, bem como realizar o mapa de cobertura de uso e ocupação do solo de regiões do bioma Caatinga. Para caracterização espectral das áreas, foram obtidas imagens do satélite Landsat-8 (sensor OLI) com resolução espacial de 30 m do período chuvoso (mês de maio) e do período seco (mês de outubro) do ano de 2018, que passaram por correção atmosférica pelo método DOS 1 (Dark Object Substraction), pela rotina do SCP plugin (QGis 2.18). Foi analisada a capacidade dos índices: NDVI, SAVI, EVI, IAF, MSAVI2 e NDWI, para verificar a sazonalidade da vegetação. Com o intuito de obter o mapa de ocupação e uso do solo dos municípios estudados foi utilizada a plataforma Google Earth Engine (GEE) e imagens Landsat-8 durante o período de 2014 a 2018. Verificou-se pela análise do comportamento espectral que a vegetação monitorada em Ouricuri apresentou maior FRBS na banda do infravermelho e menor FRBS nas bandas do vermelho e do azul, isso fez com que esta vegetação produzisse maiores índices de espectrais com relação às demais localidades. Através da matriz de confusão foi possível notar que em Tauá, de um total de 465 pontos estabelecidos como verdade de campo, 426 pontos concordaram com a classificação, o que representa uma exatidão global de 91%, e um índice Kappa de 89%, e em Ouricuri, dos 468 pontos estabelecidos como verdade de campo, 423 pontos concordaram com a classificação, que resultou numa exatidão global de 90%, e um índice Kappa de 86%. O modelo de classificação por meio da ferramenta Google Earth Engine se mostrou eficaz em verificar a mudança temporal e espacial do uso e ocupação do solo, possibilitando identificar locais com vegetação mais afetada e susceptível à degradação, e a partir disso focar apoios políticos para minimizar os danos sobre o bioma Caatinga.

**Palavras-chave:** Índices espectrais, Google Earth Engine, fator de refletância bidirecional de superfície, classificação de imagens.

## ABSTRACT

The aim of this study was to characterize the spectral responses, evaluating the seasonality of the surface reflectance bidirectional (SRB) and the spectral vegetation indices of fragments of rangelands, as well as to make the map of land use cover of regions of the Caatinga Biome. For spectral characterization of the areas, images were obtained from the Landsat-8 satellite (OLI sensor) with spatial resolution of 30 meters from the rainy period (May) and the dry period (October) from 2018, which underwent correction atmospheric by the method DOS 1 (Dark Object Substraction), by the routine of the SCP plugin (QGis 2.18). The capacity of the indices: NDVI, SAVI, EVI, IAF, MSAVI2 and NDWI was analyzed to verify the vegetation seasonality. The Google Earth Engine (GEE) platform and Landsat-8 images were used in order to obtain the land use and occupation of the studied cities during the period from 2014 to 2018. It was verified by the analysis of the spectral behavior that the vegetation monitored in Ouricuri showed higher SRB in the infrared band and lower SRB in the red and blue bands, and this caused the vegetation to produce higher spectral indices compared to the other locations. Through the confusion matrix it was possible to notice that in Tauá, from a total of 465 points established as field truth, 426 points agreed with the classification, which represents an overall accuracy of 91%, and a Kappa index of 89%, and in Ouricuri, of the 468 points established as field truth, 423 points agreed with the classification, which resulted in an overall accuracy of 90%, and a Kappa index of 86%. The classification model using the Google Earth Engine tool proved to be effective in verifying the temporal and spatial change in land use and occupation, making it possible to identify places with the most affected vegetation and susceptible to degradation, and from there to focus political support for minimize damage to the Caatinga biome.

**Keywords:** Google Earth Engine, image classification, Spectral indices, surface reflectance factor

### 3.1 INTRODUÇÃO

A Caatinga tem sido essencialmente utilizada para fins pastoris e a eficiência do uso da vegetação depende muito da condição estrutural da vegetação (HERMANCE et al., 2015). O monitoramento da dinâmica das vegetações nativas é um indicativo das estratégias e dos planos de manejo para alcançar o uso racional e a sustentabilidade do ecossistema (ZHANG et al., 2016). Nesse sentido, as ferramentas de sensoriamento remoto possuem um potencial significativo para monitorar a dinâmica da vegetação e isso permite verificar eventos como o início ou pico do crescimento da vegetação. Além disso, um dos benefícios do sensoriamento remoto é a possibilidade de realizar a avaliação de grandes áreas com boa resolução espacial e baixo custo (SALIMON & ANDERSON, 2017).

O sensoriamento remoto é, na maioria das vezes, realizado ao nível orbital, por meio da geração de imagens da superfície terrestre captadas por sensores a bordo dos satélites. Para Verrelst et al. (2019), os avanços nos estudos com sensoriamento remoto da vegetação se devem: (1) à melhoria das ferramentas computacionais, (2) à maior acessibilidade de imagens espectrais, e (3) ao progresso constante na tecnologia de sensores de espectroscopia de imagem, que vem produzindo melhores sensores a cada dia, de modo que este progresso permite inferir propriedades sutis e dinâmicas da vegetação.

O Landsat-8, um satélite oriundo de projeto Landsat de colaboração entre a NASA (National Aeronautics and Space Administration) e USGS (United States Geological Survey), fornece informações globais com resolução espacial moderada e imagens espectrais com comprimentos de onda variando da luz visível, passando por infravermelho e ondas curtas e indo até radiação termal (ROY et al., 2014). Este satélite transporta a bordo um sensor óptico chamado de OLI (Operational Land Imager), que produz imagens espectrais com resolução espacial de 30 m, resolução radiométrica de 16 bits e um período de revisitação do mesmo local de 16 dias (GANEM et al., 2017). O projeto Landsat foi desenvolvido para realização de coleta de dados globais por meio do programa NASA Earth Science, com o intuito de compreender as modificações ocorridas na terra e associá-las a riscos de catástrofes naturais, alterações induzidas pelo homem e permitir uma melhor previsão do clima e suas mudanças temporalmente (IRONS et al., 2012).

A premissa básica da aplicação do sensoriamento remoto na avaliação de vegetações é que as diferenças ou mudanças podem ser identificadas através de variações de respostas espectrais e captadas por imagens (ZHANG et al., 2003), as quais são processadas por programas computacionais chamados de sistemas de informação geográfica. A partir desse princípio, criaram-se os índices espectrais de vegetação, que tem sido frequentemente

utilizados para a avaliação de pastagens através de sensoriamento remoto (REN et al., 2018). Porém, a escolha do índice mais adequado para representar determinada vegetação demanda estudos básicos, que relacionem a variabilidade das condições estruturais com os fatores de refletância bidirecional de superfície dos diferentes canais ou bandas espectrais.

As plataformas de sensoriamento remoto por satélite oferecem registros temporais de imagens, os quais possibilitam estudos sobre a dinâmica de mudança e alterações dos biomas. Segundo Midekisa et al. (2017), quantificar e monitorar a dinâmica espacial e temporal da mudança da cobertura terrestre é fundamental para o melhor entendimento da causa de muitos processos que acarretaram modificações irreversíveis dos biomas.

O mapeamento da cobertura de áreas de pastagens nativas numa escala temporal e espacial fornece informações úteis no gerenciamento dos biomas e da cobertura da terra (JONES et al., 2018), de modo que informações consistentes na mudança da vegetação e sua dinâmica temporal podem servir de apoio às decisões políticas necessárias. Beuchle et al. (2015) analisaram a dinâmica das mudanças do uso e ocupação do solo nos biomas Cerrado e Caatinga no período de 1990 a 2010. Os resultados mostraram redução de cerca de 143.205 km<sup>2</sup> de área de floresta nos dois biomas, resultando numa perda grande e contínua da vegetação para ambos durante as duas décadas avaliadas.

Durante muito tempo, o mapeamento da mudança do uso e ocupação do solo por meio do sensoriamento remoto apresentava limitações computacionais devido à necessidade de computadores avançados para o processamento das imagens (JONES et al., 2018). A plataforma Google Earth Engine (GEE) tem auxiliado nos estudos sobre desmatamento, incidências de seca, desastres ambientais, segurança alimentar, gerenciamento dos recursos hídricos e monitoramento climático, sendo uma plataforma útil não apenas aos cientistas, mas também para o público interessado em realizar classificação de imagens por meio da computação em nuvem (GORELICK et al., 2017).

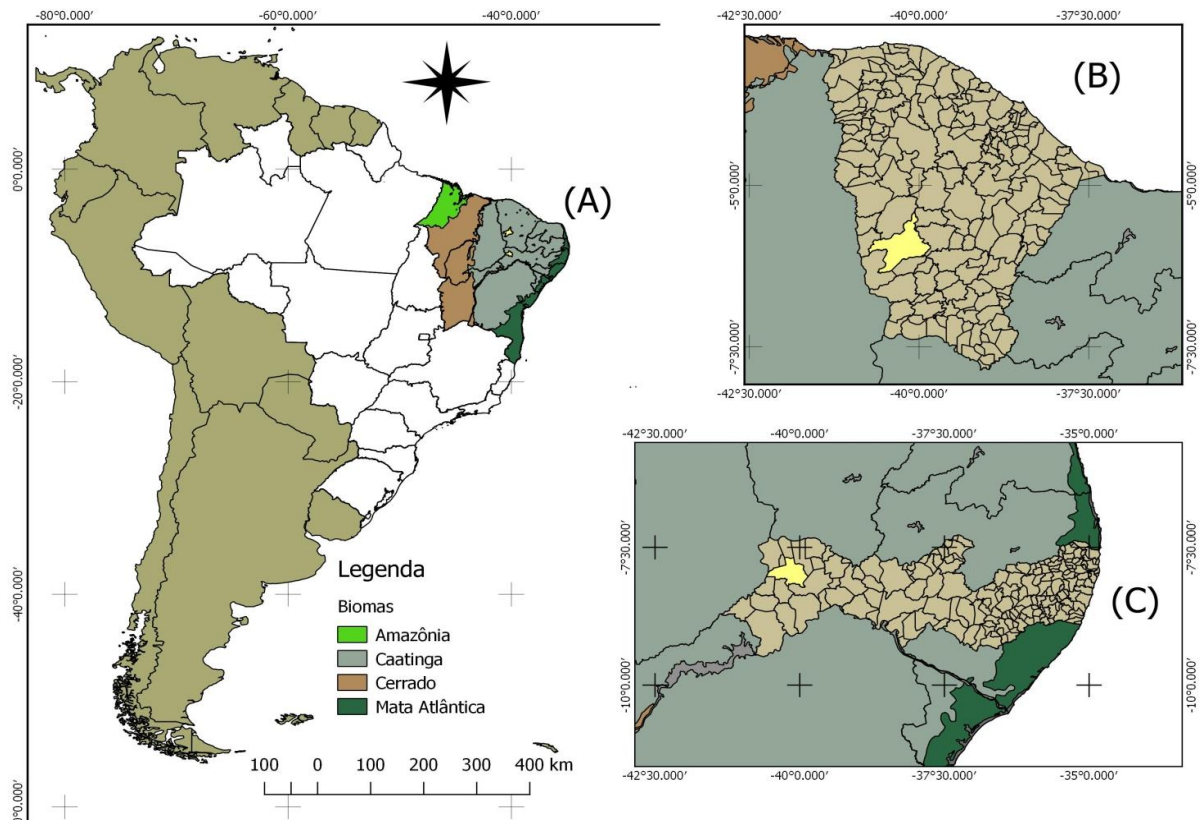
Com base no exposto, o objetivo deste estudo foi caracterizar o comportamento espectral, avaliando a sazonalidade dos valores de refletância bidirecional de superfície e dos índices espectrais de vegetação de três diferentes fragmentos de pastagem nativa, bem como avaliar as mudanças no uso e ocupação do solo de diferentes municípios localizados no bioma Caatinga.

## 3.2 MATERIAL E MÉTODOS

### 3.2.1 Caracterização da área de estudo

O estudo de campo foi conduzido em três fragmentos de pastagens nativas com diferentes níveis de densidade lenhosa da vegetação. Destes, dois fragmentos foram estabelecidos no município de Tauá, pertencente ao estado do Ceará (Figura 12B) e mais um no município de Ouricuri, estado de Pernambuco (Figura 12C), sabendo que os dois municípios estão localizados nos limites geográficos do bioma Caatinga (Figura 12A).

Figura 12 - Biomas integrantes da região do Nordeste brasileiro (A), municípios que foram estabelecidas as vegetações para a análise espectral: Tauá (B), no estado do Ceará, e Ouricuri (C), no estado de Pernambuco.




Fonte: Elaborado pelo autor.

Foram monitorados três fragmentos de pastagem nativa, sendo que dois estão situados na fazenda Cachoeirinha do Pai Senhor (Latitude  $-5.62^{\circ}$  S e Longitude  $-40.12^{\circ}$  W), pertencentes ao distrito Barra Nova, município de Tauá-CE; e um terceiro fragmento no município de Ouricuri-PE (Latitude  $-7.97^{\circ}$  S e Longitude  $-40.15^{\circ}$  W). As vegetações locais são típicas do bioma Caatinga, pois consistem numa mistura de plantas herbáceas (gramíneas e leguminosas) e lenhosas (arbustos, subarbustos e árvores), resultando em um ambiente

heterogêneo, de modo que a grande diversidade florística é resultado das diversas condições fitoecológicas presentes (AQUINO et al., 2018). Segundo Araújo Filho (2013), grande parte das espécies herbáceas, assim como as arbustivas e arbóreas de pequeno porte, são espécies utilizadas por animais ruminantes durante o pastejo (Figura 13A). Além disso, as espécies arbóreas de grande porte geralmente são caducifólias, perdendo suas folhas no início da estação seca e essa folhagem torna-se fonte de alimento para os animais.

Foram estabelecidos transetos permanentes do tipo quadrantes nos locais. Os transetos apresentam forma de cruz, gerando 4 quadrantes com 25 m de comprimento para cada lado a partir do centro para fim de descobrir a densidade lenhosa da vegetação. A partir da obtenção da densidade lenhosa, denominou-se que cada fragmento de pasto nativo receberia o nome correspondente à densidade da sua vegetação: Ouricuri com densidade de 292 plantas/ha de OD292 (Figura 13B-C); Tauá com densidade total de 144 plantas/ha foi denominada de TD144 (Figura 13D-E); Tauá com densidade de 280 plantas/ha de TD280 (Figura 13F-G).

Figura 13 - Vegetação nativa da Caatinga com a presença de bovinos pastejando (A). B e C correspondem a OD292 período chuvoso e seco, D e E correspondem a TD144 período chuvoso e seco; F e G à TD280 período chuvoso e seco.

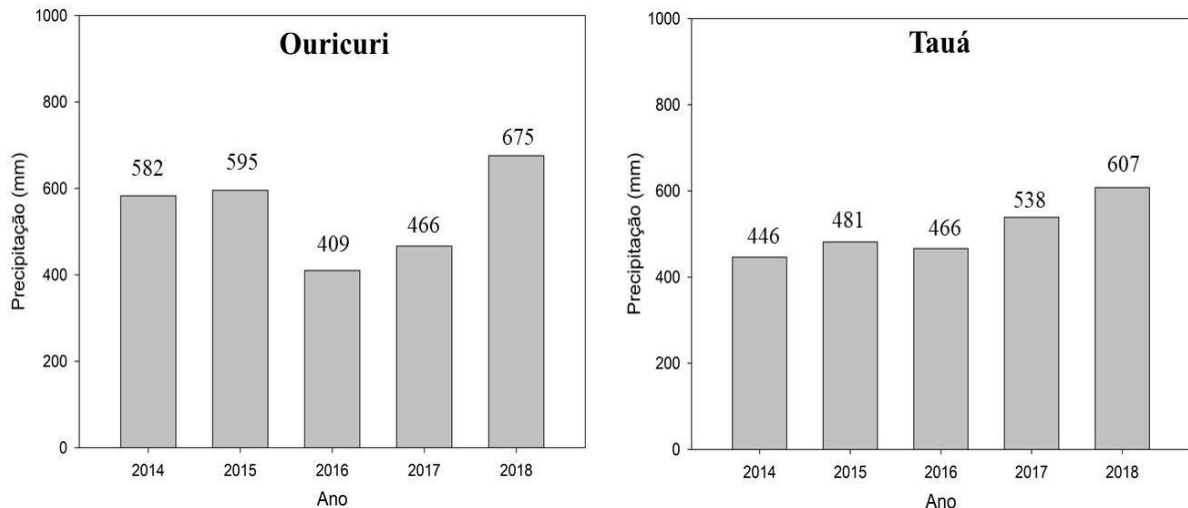


Fonte:Elaborado pelo autor.

A escolha dos municípios de Ouricuri e Tauá foi pela variabilidade de precipitação (Figura 14), solo e estrutura da vegetação, que pudessem representar a variabilidade das diferentes fitoecologias da Caatinga, associado ao fato de historicamente a pecuária ser uma

importante atividade econômica para estas regiões.

Figura 14 - Precipitação média anual dos municípios de Ouricuri e Tauá. Dados provenientes da Climate Hazards Group Infrared Precipitation (Para mais informações sobre o banco de dados CHIRPS, consulte o Capítulo 1 dessa tese).



Fonte: Elaborado pelo autor.

### 3.2.2 Caracterização espectral de fragmentos de pastagens nativas

Após a definição da densidade lenhosa da vegetação, delimitou-se a poligonal do fragmento de pasto nativo, com a obtenção dos limites através de pontos de controle terrestre, obtidos por GPS de navegação Garmim Etrex 10 e, em seguida, processados na ferramenta Google Earth Pro. Foram obtidas imagens do satélite Landsat-8 junto ao USGS (United States Geological Survey) na plataforma Earth Explorer nas seguintes datas: 28/05/2018 e 19/10/2018 (Tauá), 28/05/2018 e 10/10/2018 (Ouricuri), de modo que as imagens obtidas no mês de maio referem-se ao período chuvoso e as de outubro ao período seco.

Após a obtenção dos dados, os mesmos passaram pelo procedimento de correção atmosférica para obtenção de fatores de refletância da superfície a partir da extensão do Semi Automatic Classification Plugin (CONGEDO, 2016) presente como complemento para classificação de imagens de satélite do programa computacional Qgis (2.18). O método utilizado para a correção foi o DOS (Dark Object Subtraction), proposto por Chavez (1988) e Chavez (1989), o qual corrige a interferência dos efeitos atmosféricos a partir dos números digitais da imagem de satélite, ignorando a absorção da radiação atmosférica.

Para a avaliação do comportamento espectral das vegetações, gerou-se a curva fator de refletância bidirecional de superfície (FRBS) para cada fragmento de pastagem nativa

durante a estação chuvosa e estação seca. Para isso, foi necessário realizar o empilhamento das bandas espectrais e a extração dos valores contidos nos pixels das imagens:  $\rho b2$  (Azul),  $\rho b3$  (verde),  $\rho b4$  (vermelho),  $\rho b5$  (infravermelho próximo),  $\rho b6$  (SWIR 1) e  $\rho b7$  (SWIR 2), com auxílio do programa QGIS (versão 2.18) através do Semi-Automatic Classification Plugin (CONGEDO, 2016). O critério para seleção dos pixels foi através da criação de 50 pontos aleatórios no polígono correspondente à área da pastagem e em cada ponto foram amostrados os valores de FRBS. Em seguida, foram obtidos os índices espectrais de vegetação por meio da ferramenta calculadora ‘raster’ do Software livre QGIS (versão 2.18), que estão descritos na tabela 4.

Tabela 4 - Índices espectrais de vegetação utilizados para caracterização espectral das vegetações

Abreviação	Fórmula	Referência
NDVI <sup>α</sup>	$\frac{(\rho b5 - \rho b4)}{(\rho b5 + \rho b4)}$	Pearson & Miller, (1972)
SAVI <sup>β</sup>	$\frac{(1 + L) * (\rho b5 - \rho b4)}{(\rho b5 + \rho b4 + L)}$	Huete (1988)
MSAVI <sub>2</sub> <sup>Ω</sup>	$2 * \rho b5 + 1 - \frac{\sqrt{(2\rho b5 + 1)^2 - 8(\rho b5 - \rho b4)}}{2}$	Qi et al. (1994)
NDWI <sup>¶</sup>	$\frac{(\rho b5 - \rho b6)}{(\rho b5 + \rho b6)}$	Gao et al. (1996)
EVI <sup>∞</sup>	$\frac{2.5 * (\rho b5 - \rho b4)}{(1 + \rho b5 + C1 * \rho b4 - C2 * \rho b2)}$	Huete, (1994)
IAF <sup>*</sup>	$\frac{-\ln \frac{(0.69 - Savi)}{0.59}}{0.91}$	Asrar et al. (1996)

<sup>α</sup>Índice de Vegetação Pela Diferença Normalizada; <sup>β</sup>Índice de Vegetação Ajustado ao Solo; <sup>Ω</sup>Índice de Vegetação Ajustado ao Solo Modificado; <sup>¶</sup>Índice de Água pela Diferença Normalizada; <sup>∞</sup>Índice de Vegetação Realçado; <sup>\*</sup>Índice de Área Foliar. Nas fórmulas:  $\rho b5$  = Infravermelho;  $\rho b2$  = Azul;  $\rho b4$  = Vermelho;  $\rho b6$  = Infravermelho de ondas curtas 1 (SWIR1); L = coeficiente de ajuste da exposição do solo; C1 e C2 são Coeficientes de resistência a aerossóis e correspondem à 7.5 e 2.5 respectivamente.

Na aplicação do SAVI, variou o coeficiente de ajuste do solo: adotou-se L=0,5 para a vegetação com menor densidade e de L=0,25 para a vegetação com maior densidade, pois a menos densa existe maior contribuição do elemento solo. Para verificar a capacidade dos índices em diferenciar os locais estudados e a sazonalidade da vegetação foi realizada a comparação de dois grupos, através de análise não paramétrica com aplicação do teste t de

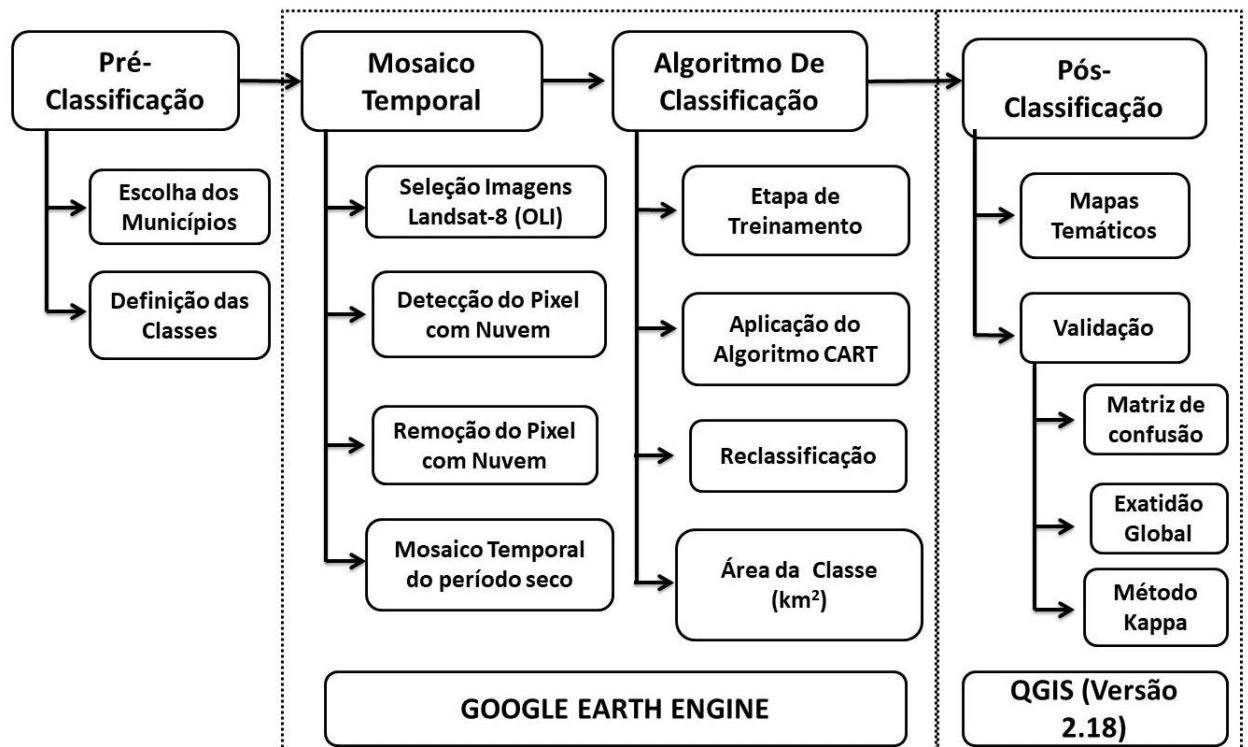


Wilcoxon para duas amostras considerando um nível de significância de 5% com auxílio do *software* SAS Studio. O comportamento espectral foi apresentado por gráficos e os índices espectrais de vegetação através de gráficos box-plot com auxílio do *software* Sigma Plot (versão 11.0).

### 3.2.3 Análise da mudança do uso e ocupação do solo de municípios localizados no bioma Caatinga

Foi realizada a análise da mudança do uso e ocupação do solo dos municípios de Ouricuri e Tauá para fim de verificar a mudança referente às áreas correspondentes às vegetações nativas susceptíveis ao pastejo animal. Para este fim, foram utilizadas imagens do Landsat-8, sensor OLI (Operational Terra Imager) as quais foram processadas na plataforma Google Earth Engine (GEE) e no programa QGIS versão 2.18 (Figura 154).

Figura 15 - Fluxograma simplificado das etapas realizadas para geração dos mapas de uso e ocupação do solo



Fonte: Elaborado pelo autor.

A primeira etapa de processamento das imagens foi realizada na plataforma Google Earth Engine (GEE). O GEE possui uma interface de programação em plataforma da *web* e uma coleção de ferramentas analíticas geoespaciais, o que facilita a acessibilidade e garante

aos usuários a possibilidade de acessar e realizar os procedimentos sem limitações relacionadas à capacidade de armazenamento de dados ou de processamento computacional (FRAKE et al., 2020). A segunda etapa consistiu na produção de mapas e validação do método de classificação no QGis (Figura 4).

Foram utilizadas imagens Landsat 8 calibrada para refletância no topo de atmosfera (TOA), conforme Chander et al. (2009). Em seguida, as imagens Landsat-8 passaram pelo processo de remoção de nuvem e geração do mosaico temporal correspondente ao período seco de cada ano de estudo. Durante a remoção da nuvem foi utilizado um algoritmo que calcula a probabilidade da presença de nuvem no intervalo de zero a cem, por meio da combinação do brilho, temperatura e NDSI (Normalized-Difference Snow Index) contidos no píxel. Após identificado o píxel correspondente à presença de nuvem, o mesmo foi removido para dar lugar ao píxel da imagem posterior disponível e calculada a mediana dos pixels sem a presença de nuvens. Após o processo de remoção das nuvens foi gerado um mosaico correspondente à composição de todas as cenas referentes ao período seco de cada ano de estudo.

As composições anuais geradas foram utilizadas para realizar a classificação supervisionada píxel a píxel, por meio do método CART (Classification and Regression Trees), proposto por Breiman et al. (2017). O método de classificação CART consiste num algoritmo que verifica a correlação de variáveis baseada em árvores de decisão (Random Forest), em que cada árvore consiste uma nova amostra que é gerada a partir dos dados originais, de modo que em cada nó de decisão o algoritmo seleciona os pixels mais semelhantes em suas respectivas classes (OTGONBAYAR et al., 2019). A Tabela 5 apresenta detalhadamente as classes usadas neste estudo.

Tabela 5. Caracterização das classes de uso e ocupação do solo usadas neste estudo e a quantidade pontos definidos durante a amostragem de treinamento da classificação

Classe	Descrição	Pontos
Caatinga Conservada	Caatinga com vegetação densa e presença de plantas arbóreas caducifólias com alta biomassa, e vegetação classificada como Savana-Estépica (Caatinga do Sertão Árido) e a Floresta Estacional Semidecidual conforme IBGE (2012).	180
Caatinga Raleada	Caatinga aberta e em estágio de sucessão secundária, caracterizado por um estrato arbustivo-arbóreo constituído por uma pequena densidade de espécies, caracterizado como uma Savana-Estépica Arborizada conforme IBGE (2012)	270
Vegetação	Vegetação com predominância de estrato herbáceo e sem a presença de plantas arbóreas ou arbustivas, classificada como	150

herbácea	vegetação Savana-Estépica Gramíneo-Lenhosa conforme IBGE (2012).	
Solo Exposto	Áreas com cobertura variada tais como afloramentos rochosos, e demais áreas que prevalecem com solo exposto durante o período seco do ano.	200
Água	Incluem todas as feições que contém água: reservatórios, rios, riachos, lagoas, entre outros.	150
Outros	Áreas urbanas, asfalto, áreas de construção civil e outras infraestruturas.	40

O critério para definição das classes se baseou no interesse do presente estudo de verificar a mudança temporal das áreas de vegetação de Caatinga. No total, foram obtidos 990 pixels para cada ano considerando os dois locais de estudo. No total foram amostrados 4950 pixels sobre as imagens correspondentes aos locais durante os 5 anos de estudo, os quais foram utilizados para treinamento do algoritmo em identificar as 5 classes.

Após a classificação foram avaliados a acurácia e a exatidão da mesma, por meio da aplicação da matriz de confusão, índice kappa e índice de concordância global. Foram definidas amostras a partir de imagens de alta resolução do Google Earth Pro e, em seguida, realizada a checagem por interpretação visual com uso da imagem classificada do Landsat-8. As amostras criadas foram checadas e definidas como dados de referência (verdade de campo), para posteriormente construir a matriz de confusão e, a partir desta, obter o índice Kappa e os coeficientes de concordância com o auxílio do programa Qgis (2.18).

### 3.3 RESULTADOS E DISCUSSÃO

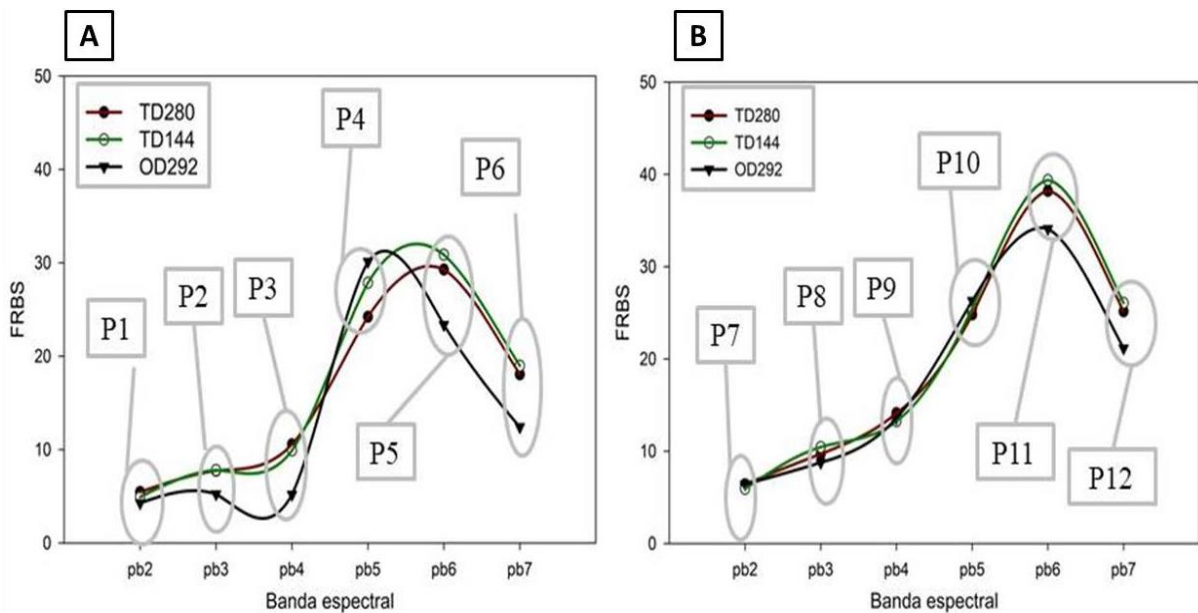
#### 3.3.1 Caracterização espectral e índices de vegetação de fragmentos de pastagens nativas do bioma Caatinga

Independentemente do local de monitoramento, foi observado um padrão de comportamento espectral da vegetação, com baixos valores de FRBS das bandas espectrais que correspondem ao azul, vermelho e verde; e elevados valores de FRBS do infravermelho durante a estação chuvosa. A Caatinga OD292 apresentou menores refletâncias das bandas pb2, pb3 e pb4 (comprimentos de onda do visível), com valores de FRBS de 4,2; 5,2 e 5,1%, respectivamente (Pontos P1, P2, P3 na Figura 16A) e maiores refletâncias na banda pb5 (P4 na Figura 16A).

As duas vegetações localizadas no município de Tauá tiveram comportamento semelhante com relação ao FRBS da banda pb4, porém observou-se que a Caatinga TD144 apresentou maiores valores de FRBS quando comparada à Caatinga TD280. Analisando o período seco do ano, também se observou um padrão de FRBS das diferentes vegetações para

os comprimentos de onda do visível, porém foi mais nítida maior FRBS na região do infravermelho de ondas curtas, que corresponde às bandas pb6 e pb7, (Figura 16B ponto 11 e ponto 12) quando comparado ao período chuvoso do ano (Figura 16A, ponto 5 e ponto 6).

Figura 16 - Fator de refletância bidirecional de superfície (FRBS) de fragmentos de pastagens com diferentes densidades da vegetação lenhosa nos municípios de Ouricuri e Tauá no período chuvoso (A) e seco do ano (B) de 2018.



Fonte: Elaborado pelo autor.

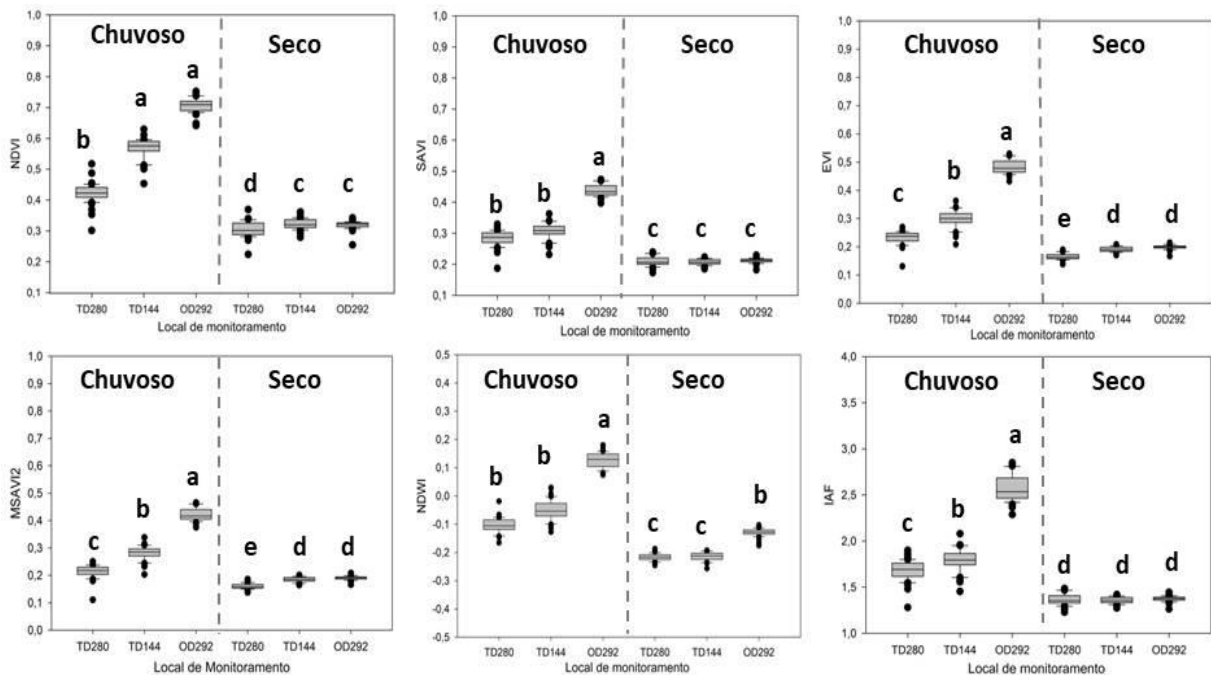
Menores valores de FRBS dos comprimentos de onda, correspondentes à luz do visível durante o período seco do ano, devem-se às modificações na morfologia característica da vegetação nativa do bioma Caatinga ao longo do ano e isso provoca variações nas frações absorvidas, transmitidas e refletidas da radiação solar incidente. Comparando as diferentes localidades, é importante ressaltar que houve diferença na FRBS das vegetações, muito possivelmente devido ao município de Ouricuri ter registrado maior precipitação quando comparado a Tauá, o que pode ter proporcionado uma vegetação mais abundante e vigorosa, resultando numa maior absorção dos comprimentos de onda na faixa do visível.

Segundo Hatfield et al. (2008), a compreensão da refletância foliar é importante quando a proposta é monitorar a vegetação por métodos de sensoriamento remoto, e foi a partir desta compreensão que se tornou possível a criação de vários índices para estimar parâmetros da vegetação como a área foliar, cobertura vegetal, biomassa, estrutura e produtividade. Além disso, o padrão de FRBS das vegetações possibilita avaliar o potencial fotossintético de uma vegetação, a presença ou não de pigmentos, o conteúdo de água, a cobertura da vegetação e a

presença de material senescente (HILL et al. 2013).

Verificando a variação sazonal dos índices espectrais de vegetação (Figura 17), notou-se que todos os índices apresentaram maiores valores na vegetação OD292. Considerando as vegetações monitoradas em Tauá (TD280 e TD144), os índices NDVI, EVI, MSAVI2 e IAF foram capazes de distinguir as vegetações durante o período chuvoso e a Caatinga com menor densidade lenhosa (TD144) apresentou os maiores índices, mas SAVI e NDWI não foram capazes de diferenciá-las.

Figura 17 - Índices espectrais de vegetação aplicados a fragmentos de pasto nativo com diferente densidade lenhosa em Ouricuri e Tauá. Valores com letras distintas dentro de um mesmo índice diferem entre si pelo teste t de Wilcoxon ( $P < 0,05$ )



Fonte: Elaborado pelo autor.

Comparando as estações e numa mesma vegetação, não houve diferença para os índices SAVI e IAF. O EVI e o MSAVI foram os dois índices mais eficientes em distinguir as vegetações, tanto considerando a variação de densidade lenhosa da vegetação quanto sua sazonalidade. Um fator que pode ter contribuído para os maiores índices de vegetação em Ouricuri são as características do solo do fragmento de pastagem OD280 que, sendo classificado como franco areoso, possui características texturais de que dão melhor condição estrutural de infiltração e armazenamento de água no perfil solo quando comparado ao solo de Tauá possui um solo fraco argilo arenoso.

Na Caatinga existe grande quantidade de plantas caducifólias, que sofrem efeitos

diretos da disponibilidade hídrica (BARROS & SOARES, 2013). Portanto, os menores valores para os índices espectrais de vegetação durante o período seco do ano em detrimento ao período chuvoso se devem às menores precipitações no segundo semestre do ano. Como resposta à escassez hídrica, a vegetação perde a folhagem para reduzir a perda de água por transpiração. Então, os maiores valores dos índices espectrais no período chuvoso ocorreram pelo maior vigor da vegetação durante essa estação do ano, principalmente, devido à maior quantidade de pigmentos fotossintéticos encontrados principalmente em órgãos fotossinteticamente ativos.

Os valores de NDVI médios sempre foram maiores que os demais índices analisados neste estudo, tanto durante o período chuvoso quanto no período seco. Existe uma vasta literatura que relaciona índices espectrais de vegetação com parâmetros biofísicos das vegetações e, para Gu et al. (2007), o NDVI tem sido um dos mais úteis, pois indica mudanças no conteúdo de clorofila, por meio da absorção da radiação vermelha e modificações no mesofilo esponjoso, através da reflexão da radiação infravermelha dentro do dossel da vegetação. Apesar do NDVI ser um dos índices mais utilizados, em algumas situações de vegetação abundante e densa ele tende à saturação (LU et al., 2014). Então, alguns outros índices foram desenvolvidos, como o SAVI e o EVI, que possuem coeficientes para corrigir as influências atmosféricas e de solo respectivamente (HUETE et al., 2002) e pela presença destas constantes de correção produzem menores valores de EVI e SAVI com relação ao NDVI (HA et al. 2001).

Neste estudo, o EVI e o MSAVI<sub>2</sub> foram os índices mais eficientes em distinguir às vegetações considerando as diferentes localidades e a modificação sazonal. Conforme Becerra et al. (2009), o EVI foi um índice desenvolvido para otimizar a resposta da vegetação por considerar em seu cálculo as correções das distorções da luz refletida pelo material suspenso no ar, assim como pela cobertura do solo sob o dossel da vegetação. Laosuwan & Uttaruk (2014) analisaram a eficiência de um modelo composto pelo MSAVI<sub>2</sub> em simular a variação da biomassa de árvores na Tailândia e classificaram este índice como eficiente em verificar mudanças na vegetação ao longo do tempo. Possivelmente, isso acontece devido ao MSAVI<sub>2</sub> ser um índice que possui correlação positiva com as modificações estruturais presentes na vegetação, pelas correções das influências do solo nas respostas espectrais da vegetação (ZHANG et al., 2005).

A fim de analisar a caatinga para fins pastoris, o IAF é um importante índice indicador de parâmetros biofísicos das pastagens (YUAN et al. 2017), possuindo relação direta com fotossíntese, evapotranspiração, interceptação de radiação e de precipitação e fluxo de

carbono em áreas de pastagens (SHA et al., 2019). Segundo Zhang & Kovacs, (2012), durante os primeiros estágios de crescimento da vegetação, a folha é o componente morfológico mais acumulado na biomassa das pastagens. Com o início das chuvas, há as brotações da vegetação arbustiva e arbórea da Caatinga, bem como o surgimento do estrato herbáceo, porém, com o avançar do período seco a vegetação lenhosa reduz o IAF, restando basicamente o IAF pertencente ao estrato herbáceo da vegetação, que também é reduzido devido à senescência e morte das plantas herbáceas.

### 3.3.2 Uso e ocupação do solo em regiões do bioma Caatinga

Tanto o município de Tauá quanto o de Ouricuri registraram aumento da área de Caatinga conservada e redução da área de Caatinga Raleada (Tabela 6), sendo que em Tauá a área de Caatinga conservada aumentou de 1423,7 km<sup>2</sup> em 2014 para 2025,9 km<sup>2</sup> em 2018, o que representou um incremento de 602 km<sup>2</sup> e de 42% da área de vegetação conservada, enquanto em Ouricuri também ocorreu aumento da área de Caatinga conservada, que passou de 612,9 km<sup>2</sup> em 2014 para 1059,2 km<sup>2</sup> (aumento de 72,8 %).

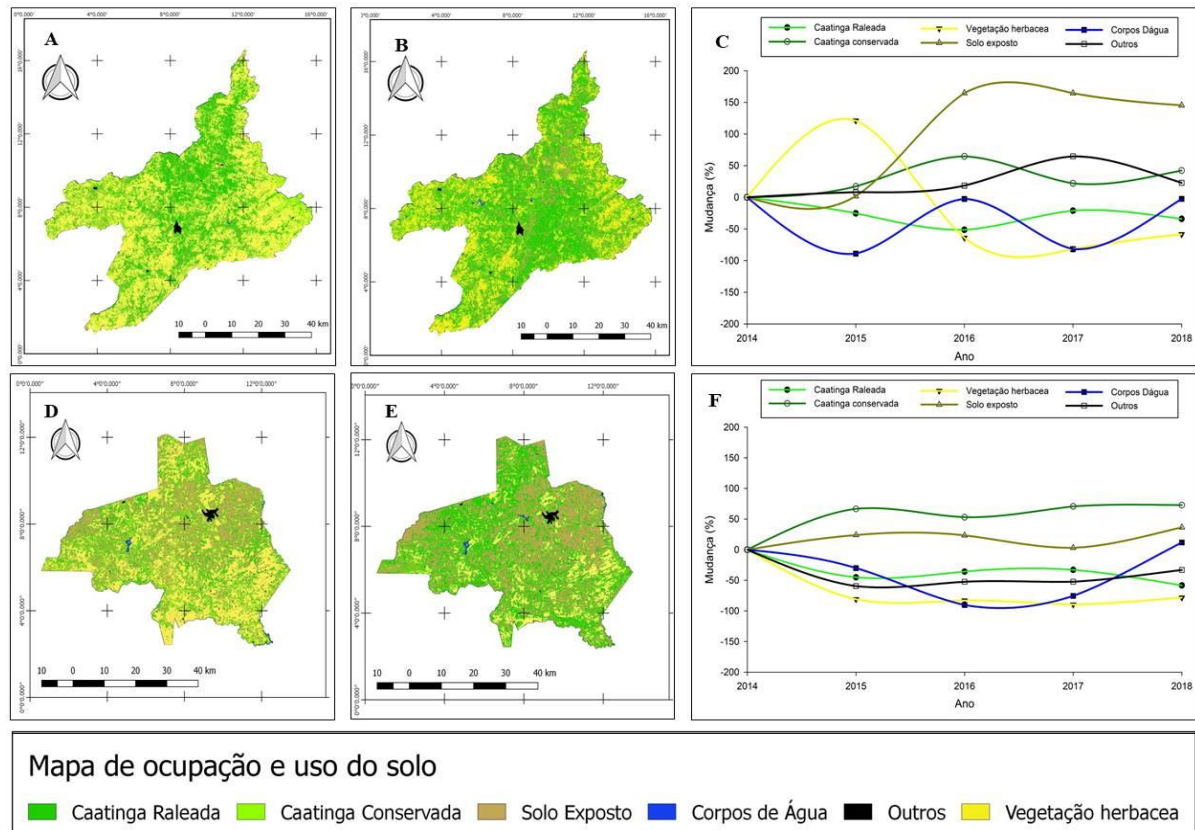
Tabela 6 - Mudança da cobertura do solo (km<sup>2</sup> e em %), obtidos através de imagens Landsat 8 (OLI) processadas na plataforma Google Earth Engine

Classe	2014	2018	Mudança (km <sup>2</sup> )		Mudança (%)	
			Tauá			
Caatinga Raleada	2155,8	1424,5	-731,2	-33,9		
Caatinga Conservada	1423,7	2025,9	602,3	42,3		
Vegetação Herbácea	242,6	101,1	-141,6	-58,3		
Solo exposto	176,4	432,9	256,5	145,3		
Corpos D'água	12,3	12,6	2,44	0,31		
Outros	18,7	20,3	4,3	22,9		
Ouricuri						
Caatinga Raleada	980,4	408,8	-571,5	-58,3		
Caatinga Conservada	612,9	1059,2	446,3	72,8		
Vegetação Herbácea	123,2	26,8	-96,3	-78,17		
Solo exposto	631,0	861,3	230,3	36,49		
Corpos D'água	6,0	6,7	0,71	11,79		
Outros	29,59	19,81	-33,05	-9,78		

Em Tauá, notou-se uma redução na área de Caatinga raleada e de vegetação herbácea numa análise dos mapas de uso e ocupação do solo (Figura 18A-B), na ordem de 33,9 e 58,3 %, respectivamente, enquanto houve aumento de 145% na área de solo exposto. É visível nos mapas o aumento da classe de solo exposto, bem como o aumento da área de Caatinga conservada comparando 2014 a 2018. A Figura 18C-F apresenta as modificações das 5

classes analisadas ao longo do período de estudo. Em Tauá (Figura 18 C), houve aumento da classe solo exposto a partir do ano 2016, enquanto se verificou redução da área de vegetação herbácea e Caatinga raleada.

Figura 18 - Mapas temáticos do uso e ocupação do solo dos municípios de Tauá (A-B) e Ouricuri (D-E) entre os anos de 2014 e 2018, e mudança interanual (%) das classes de Tauá (C) e Ouricuri (F)



Fonte. Elaborado pelo autor.

Em Ouricuri houve redução da área de Caatinga raleada e de vegetação herbácea na ordem de 58 e 78%, respectivamente, e um aumento da classe solo exposto de 23% (Figura 18F). A classe corpos d'água teve um aumento no ano de 2018 e em Tauá as menores modificações em 2015. Em Ouricuri e em Tauá, as maiores áreas de corpos d'água foram obtidas no ano de 2018, indicando que neste ano as precipitações resultaram no abastecimento dos reservatórios hídricos dos municípios.

Provavelmente, os aumentos da área de Caatinga conservada dos municípios de Ouricuri e Tauá ocorreram em função de alguns fragmentos de vegetações raleadas se encontrarem em processo de regeneração e sucessão ecológica, associados à redução da pressão antrópica nestas áreas. Além disso, a ação antrópica de desmatamento de fragmentos



de Caatinga raleada e de vegetação herbácea para preparo do solo e posteriormente realização do plantio das culturas agrícolas pode ter resultado no aumento da área de solo exposto nestas regiões.

A validação com o comparativo da classificação no Google Earth Engine com os dados de verdade de campo por meio através da matriz de confusão (Tabela 7), foi mostrado que em Tauá, de um total de 465 pontos estabelecidos como verdade de campo, 426 pontos concordaram com a classificação, o que representa uma exatidão global de 91% e um índice Kappa de 89%. Já em Ouricuri, dos 468 pontos estabelecidos como verdade de campo, 423 pontos concordaram com a classificação, que resultou numa exatidão global de 90%, e um índice Kappa de 86%. Tanto em Tauá quanto em Ouricuri os corpos d'água apresentaram os menores erros e a vegetação herbácea, e outros os maiores erros de omissão e de comissão.

Tabela 7 - Matriz de confusão e os erros de omissão e de comissão obtidos por meio da comparação da classificação em Google Earth Engine (esquerda) com os dados de validação observados (topo) para o ano de 2018.

Classe	Taua						Comissão
	Raleada	Conservada	Herbácea	Solo	Água	Outros	
Raleada	68	2	3	0	0	5	0,16
Conservada	3	72	0	0	4	3	0,17
Herbácea	2	0	91	0	3	0	0,20
Solo exposto	0	0	0	66	0	0	0,14
Água	0	0	0	0	4	0	0,86
Outros	2	1	6	2	3	125	0,29
Omissão	0,16	0,16	0,21	0,14	0,30	0,28	465

Classe	Ouricuri						Comissão
	Raleada	Conservada	Herbácea	Solo	Água	Outros	
Raleada	100	1	6	0	0	7	0,24
Conservada	0	20	2	0	0	5	0,057
Herbácea	2	2	132	0	3	6	0,30
Solo exposto	0	0	0	40	0	0	0,08
Água	0	0	0	3	4	0	0,014
Outros	3	0	12	9	1	127	0,32
Omissão	0,22	0,04	0,32	0,11	0,01	0,30	468

Conforme a escala de qualidade da classificação proposta por Landis & Koch (1977), os valores de índice kappa para Tauá e Ouricuri mostraram excelente nível de acerto, bem como os erros de omissão e comissão apresentaram baixos valores, sendo o maior erro de 32,48% para vegetação herbácea em Ouricuri. Muito possivelmente, um fator que pode ter auxiliado para a alta qualidade da classificação foi a utilização de imagens do período seco de cada ano,

que facilitou a distinção das classes, uma vez que nesse período seco a vegetação de Caatinga perde sua folhagem e os solos agricultáveis estão basicamente secos e expostos. Por outro lado, houve uma tendência do modelo de classificação em confundir a classe solo exposto com vegetação herbácea, possivelmente devido às áreas destinadas à agricultura nestas regiões permanecerem com solo exposto ou com restos de cultura durante o período seco do ano, confundindo-se com as plantas herbáceas.

A Caatinga é um bioma que sofre com inadequados métodos de utilização, bem como com a transformação das florestas nativas em áreas agrícolas (MOREIRA et al., 2019). Em grande parte deste bioma existem problemas de degradação e as principais causas estão relacionadas com a ausência de planejamento e de gerenciamento dos recursos naturais, principalmente com relação à riqueza e à biodiversidade da Caatinga (SOUZA et al., 2015).

Vieira et al. (2013) realizaram um levantamento da mudança do uso e ocupação do solo da região semiárida e os resultados mostraram que 57% da área estudada são ocupadas e com alta interferência antrópica sobre a vegetação, levando os autores a concluir que existe grande parte da região semiárida brasileira suscetível à desertificação, e a análise do uso e ocupação do solo forneceu uma contribuição importante para entender as regiões geográficas mais afetadas por ações antrópicas ou climáticas. O modelo de classificação de imagem adotado neste estudo foi eficiente em verificar a mudança da vegetação nativa numa análise temporal, servindo de subsídio para estimular os governos a desenvolverem ações de políticas públicas para preservação da Caatinga em regiões mais afetadas.

### **3.4 CONCLUSÃO**

A análise do comportamento espectral de pastagens nativas da Caatinga é uma prática útil e básica para a realização de estudos com sensoriamento remoto, pois possibilitou distinguir as vegetações numa análise temporal verificado através da sazonalidade da vegetação e numa escala espacial considerando os diferentes locais de monitoramento. Os índices espectrais de vegetação foram capazes de verificar mudanças sazonais na vegetação nativa da Caatinga, tornando-os úteis em analisar o estado fenológico da mesma, sugerindo que podem vir a ser úteis em estimar a condição da oferta de forragem para os rebanhos.

O modelo de uso e ocupação do solo adotado neste estudo sugere diminuição da área correspondente a classe de Caatinga raleada e aumento de Caatinga conservada, especialmente devido às áreas raleadas terem sido utilizadas para agricultura, passando por períodos de alta atividade antrópica, resultando no aumento nas áreas de solo exposto nos municípios de Ouricuri e Tauá.

## REFERÊNCIAS

- AQUINO, Deodato do Nascimento et al. Use of remote sensing to identify areas at risk of degradation in the semi-arid region. **Revista Ciência Agronômica**, Fortaleza, v. 49, n. 3, p. 420-429, 2018.
- ARAÚJO FILHO, João Ambrosio. **Manejo pastoril sustentável da caatinga**. v. 01, Cidade Gráfica e Editora Ltda., pp. 200, 2013.
- ASRAR, Ghassem et al. Light interception and leaf area estimates from measurements of grass canopy reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, Pasadena, n. 1, p. 76-82, 1986.
- BARROS, Ileana Oliveira; SOARES, Arlete Aparecida. Adaptações anatômicas em folhas de marmeleiro e velame da caatinga brasileira. **Revista Ciência Agronômica**, Fortaleza, v. 44, n. 1, p. 192-198, 2013.
- BECERRA, Jorge Alberto Bustamante; SHIMABUKURO, Yosio Edemar; ALVALÁ, Regina Célia dos Santos. Relação do padrão sazonal da vegetação com a precipitação na região de Cerrado da Amazônia Legal, usando índices espectrais de vegetação. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 24, n. 2, 125-134, 2009.
- BEUCHLE, René et al. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach. **Applied Geography**, Amsterdam, v. 58, p. 116-127, 2015.
- BREIMAN, L. et al. **Classification and regression trees**, Routledge. 2017.
- CHANDER, Gyanesh; MARKHAM, Brian L.; HELDER, Dennis L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote sensing of environment**, Amsterdam, v. 113, n. 5, p. 893-903, 2009.
- CHAVEZ, Pat S. Radiometric calibration of Landsat thematic mapper multispectral images. **Photogrammetric Engineering and Remote Sensing**, v. 55, n. 9, p. 1285-1294, 1989.
- CHAVEZ, Pat S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, Amsterdam, v. 24, n. 3, p. 459-479, 1988.
- CONGEDO, Luca. Semi-automatic classification plugin documentation. **Release**, v. 4, n. 0.1, p. 29, 2016.
- FRAKE, April N. et al. Leveraging big data for public health: Mapping malaria vector suitability in Malawi with Google Earth Engine. **PLoS one**, San Francisco, v. 15, e0235697, 2020.
- GANEM, Khalil Ali et al. Comparação entre dados com e sem correção atmosférica na classificação da cobertura da Terra de uma área da Caatinga utilizando o Google Earth Engine. **Revista Brasileira de Cartografia**, Monte Carmelo, v. 69, n. 6, 2017.

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, Amsterdam, v. 58, n. 3, p. 257-266, 1996.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, Amsterdam, v. 202, p. 18-27, 2017.

GU, Yingxin et al. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, Washington, v. 34, p. 1-6, 2007.

HATFIELD, Jerry L. et al. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, Madison, v. 100, n. 3, p. 117, 2008..

HERMANCE, John F.; AUGUSTINE, David J.; DERNER, Justin D. Quantifying characteristic growth dynamics in a semi-arid grassland ecosystem by predicting short-term NDVI phenology from daily rainfall: a simple four parameter coupled-reservoir model. **International Journal of Remote Sensing**, Abingdon, v. 36, n. 22, p. 5637-5663, 2015.

HILL, Michael J. Vegetation Index Suites as Indicators of Vegetation State in Grassland and Savanna: An Analysis with Simulated SENTINEL 2 Data for a North American Transect. **Remote Sensing of Environment**, Amsterdam, v. 137, p. 94-111, 2013.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, Amsterdam, v. 25, p. 295-309, 1988.

HUETE, Alfredo et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, Amsterdam, v. 83, n. 1-2, p. 195–213, 2002.

HUETE, Alfredo; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of environment**, Amsterdam, v. 49, n. 3, p. 224-234, 1994.

IBGE, R. **Manual técnico da vegetação brasileira**. 2ª ed. Rio de Janeiro: IBGE, 275p, 2012.

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

JONES, Matthew O. et al. Innovation in rangeland monitoring: annual, 30 m, plant functional type percent cover maps for U.S. rangelands, 1984–2017. **Ecosphere**, Washington, v. 9, n. 9, p. e02430, 2018.

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

LAOSUWAN, Teerawong; UTTARUK, Pornchai. Estimating tree biomass via remote sensing, MSAVI 2, and fractional cover model. **IETE Technical Review**, New Delhi, v. 31, n. 5, p. 362-368, 2014.

- MIDEKISA, Alemayehu et al. Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. **PLoS ONE**, San Francisco, v. 12, n. 9, p. e0184926, 2017.
- MOREIRA, Francisco TA et al. Floristic Characterization and Phytosociology of a Vegetation in a Caatinga Area in Brazil. **Journal of Experimental Agriculture International**, West Bengal, v. 30, n. 5, p. 1-10, 2019.
- OTGONBAYAR, Munkhdulam et al. Mapping pasture biomass in Mongolia using Partial Least Squares, Random Forest regression and Landsat 8 imagery. **International Journal of Remote Sensing**, Abingdon, v. 40, n. 8, p. 3204-3226, 2019.
- PEARSON, Robert Lawrence; MILLER, Lee Durward. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie. **Proceedings of the Eighth International Symposium on Remote Sensing of Environment**, v. rse, p. 1355, 1972.
- QI, Jianguo et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, Amsterdam, v. 48, n. 2, p. 119-126, 1994.
- REN, Hongrui; ZHOU, Guangsheng; ZHANG, Feng. Using negative soil adjustment factor in soil-adjusted vegetation index (SAVI) for aboveground living biomass estimation in arid grasslands. **Remote Sensing of Environment**, Amsterdam, v. 209, p. 439-445, 2018.
- ROY, David P. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, Amsterdam, v. 145, p. 154-172, 2014.
- SALIMON, Cleber; ANDERSON, Liana. How strong is the relationship between rainfall variability and Caatinga productivity? A case study under a changing climate. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 90, n. 2, p. 2121-2127, 2018.
- SHA, Zongyao et al. Comparison of leaf area index inversion for grassland vegetation through remotely sensed spectra by unmanned aerial vehicle and field-based spectroradiometer. **Journal of Plant Ecology**, Oxford, v. 12, n. 3, p. 395-408, 2019.
- SOUZA, Bartolomeu Israel; MENEZES, Rafael; CAMARA ARTIGAS, Rafael. Desertification effects on the species composition of the Caatinga biome, Paraíba/Brazil. **Investigaciones Geográficas**, San Vicente del Raspeig, v. 88, p. 45-59, 2015.
- VERRELST, Jochem et al. Quantifying vegetation biophysical variables from imaging spectroscopy data: a review on retrieval methods. **Surveys in Geophysics**, New York, v. 40, n. 3, p. 589-629, 2019.
- VIEIRA, Rita Marcia da Silva Pinto et al. Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 28, n. 2, p. 129-138, 2013.
- YUAN, Huanhuan et al. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of RF, ANN, and SVM regression models. **Remote Sensing**, Basel, v. 9, n. 4, p. 309, 2017.

ZHANG, Xiaoyang et al. Monitoring vegetation phenology using MODIS. **Remote sensing of environment**, Amsterdam, v. 84, n. 3, p. 471-475, 2003.

ZHANG, Binghua et al. Application of synthetic NDVI time series blended from Landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, Basel, v. 8, n. 1, p. 10, 2016.

ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, New York, v. 13, n. 6, p. 693-712, 2012.

ZHANG, Zhi-Ying et al. Remote sensing and spatial statistical analysis to predict the distribution of *Oncomelania hupensis* in the marshlands of China. **Acta Tropica**, Amsterdam, v. 96, n. 2-3, p. 205-212, 2005.

#### **4 CAPÍTULO III: ANÁLISE DE TÉCNICAS DE MODELAGEM PARA SIMULAÇÃO DA BIOMASSA FORRAGEIRA E MAPAS DE PRODUÇÃO DE FORRAGEM EM REGIÕES DO BIOMA CAATINGA**

##### **RESUMO**

Durante os anos de 2018 e 2019 foram realizadas colheitas de biomassa em quatro transetos estabelecidos em áreas de Caatinga com diferente densidade lenhosa, localizados em Tauá (Ceará) e Ouricuri (Pernambuco), com a finalidade de testar modelos empíricos e mecanístico em simular a biomassa de pastagem nativa. Para a estimativa da produção de biomassa no campo, uma moldura de 0,25 m<sup>2</sup> foi lançada 8 vezes no transeto para colheita do estrato herbáceo, e uma moldura de 20 m<sup>2</sup> (2 x 10 m) em cada quadrante do transeto para colheita da biomassa do estrato arbustivo-arbóreo pelo método da unidade referencial. Para a criação dos modelos empíricos a partir de dados de sensoriamento remoto foram utilizadas imagens do satélite Sentinel 2-A, as quais passaram por correção atmosférica pelo método DOS 1 (Dark Object Substraction), pela rotina do SCP plugin (QGis 2.18) e posteriormente calculados os índices de vegetação. Foram testados os índices: NDVI, SAVI, EVI, IAF, MSAVI2 e NDWI para geração de modelos empíricos a partir de dados de biomassa de forragem. Para o desenvolvimento dos modelos, foi utilizado o Software LAB Fit Curve Fitting. A calibração do modelo PHYGROW foi realizada por meio da plataforma virtual PHYWEB. O SAVI foi o índice que apresentou os melhores ajustes do modelo, sabendo que os modelos empíricos provenientes de dados de sensoriamento remoto apresentaram média capacidade de simular a produção da biomassa de forragem total em pastagens naturais da Caatinga, possivelmente por sofrer efeito da densidade de plantas lenhosas presentes na vegetação, bem como devido os dados não serem provenientes da biomassa total presente na vegetação. O PHYGROW apresentou melhor desempenho em simular a produção de biomassa, mostrando-se ser útil para estimar a produção de biomassa de áreas de Caatinga com diferentes níveis de densidade lenhosa, tornando-se uma ferramenta útil para o manejo racional de pastagens.

**Palavras-chave:** Mudanças climáticas, pastagens nativas, refletância, regiões semiáridas, taxa de lotação.

## ABSTRACT

During the years 2018 and 2019, biomass harvests were carried out in four transects established in areas of Caatinga with different woody density, located in Tauá (Ceará) and Ouricuri (Pernambuco), in order to test empirical and mechanistic models to simulate biomass of native rangeland. To estimate the biomass production in the field, a 0.25 m<sup>2</sup> frame was launched 8 times in the transect to harvest the herbaceous layer, and a 20 m<sup>2</sup> (2 x 10 m) frame in each quadrant of the biomass harvest transect of the shrub-tree stratum using the referential unit method. For the creation of empirical models from remote sensing data, images from the Sentinel 2-A satellite were used, which underwent atmospheric correction using the DOS 1 method (Dark Object Subtraction), the SCP plugin routine (QGis 2.18) and later vegetation indices were calculated. The following indices were tested: NDVI, SAVI, EVI, IAF, MSAVI2 and NDWI for generating empirical models from forage biomass data. For the development of the models, the LAB Fit Curve Fitting Software was used. The calibration of the PHYGROW model was performed using the virtual platform PHYWEB. The SAVI was the index that presented the best adjustments of the model, knowing that the empirical models derived from remote sensing data showed a medium capacity to simulate the production of total forage biomass in natural rangelands of the Caatinga, possibly due to the effect of plant density woody vegetation, as well as data are not from the total biomass present in the vegetation. PHYGROW showed a better performance in simulating biomass production, proving to be useful to estimate biomass production in areas of Caatinga with different levels of woody density, making it a useful tool for the rational management of rangelands.

**Keywords:** Climate change, native rangelands, reflectance, semi-arid regions, stocking rate.



## 4.1 INTRODUÇÃO

A distribuição irregular das precipitações em regiões do bioma Caatinga aumenta os riscos da produção de culturas agrícolas levando alguns produtores a optarem pela produção pecuária (SANTOS et al., 2010). Porém, as secas intensas e as altas taxas de lotação têm causado impactos significativos na condição da vegetação causando a degradação do bioma Caatinga. A Caatinga é um dos biomas mais ameaçados no Brasil, logo a maior parte da floresta nativa foi desmatada principalmente para a formação de áreas de pastagens em resposta à demanda imposta pela atividade pecuária do Semiárido brasileiro (SILVA et al., 2020).

No manejo de pastagens nativas existem estratégias alternativas para ajustar a taxa de lotação com base na condição da pastagem, da época do ano e da variação da condição dos animais (DÍAZ-SOLÍS et al., 2009). Os pastos nativos sofrem oscilações produtivas ao longo do ano (MAGLIANO et al. 2015), logo o entendimento dessa dinâmica é fundamental para realizar o ajuste da quantidade de animais em função da biomassa forrageira presente na pastagem. A capacidade de suporte da pastagem é determinada pela quantidade de biomassa forrageira que será ofertada aos animais (JOBAGY & SALA, 2000) e, geralmente, os métodos utilizados para determinação da biomassa em pastagens são métodos diretos através do corte e pesagem da forragem. Porém, este método de estimativa é demorado e trabalhoso, o que dificulta as avaliações em grandes áreas, principalmente quando se trata regiões de difícil acesso. Então, é importante o desenvolvimento e estudo de sistemas confiáveis de monitoramento da biomassa, que sejam práticos e de fácil acesso aos pecuaristas (SIBANDA et al., 2017).

O uso da modelagem para simulação da produção de biomassa em ecossistemas pastoris é uma ferramenta útil para caracterizar a produtividade da pastagem, servindo para diversas aplicações, entre elas auxiliar na previsão de desastres causados pelas secas. Além disso, a modelagem possibilita a realização de previsões, gerando informações que podem servir para auxiliar na tomada de decisão de políticas públicas e agrícolas (ZILVERBERG et al., 2017). Segundo Angerer (2008), os modelos mais usados para simulação da produção de pastagens são regressões simples, modelos biofísicos, técnicas de sensoriamento remoto ou a combinação destes métodos. Uma categoria de modelo que ganha destaque para obter informações biofísicas da vegetação de forma indireta bem como gerar modelos empíricos é o sensoriamento remoto.

A interpretação do sensoriamento remoto acontece devido às alterações morfológicas do dossel forrageiro resultarem em variações nas frações absorvida, transmitida e refletida da

radiação solar incidente, sendo que as variações na refletância da superfície do dossel são captadas por sensores orbitais, produzindo imagens espectrais. Os modelos empíricos com informações de sensoriamento remoto podem ser úteis na geração de mapas de produção de biomassa forrageira das pastagens, bem como na prevenção de possíveis desastres causados pelas secas. Porém, uma das limitações dos modelos empíricos é que existe uma falta de confiança quando é necessário prever a biomassa fora dos locais onde estes foram desenvolvidos, sendo necessário que o mesmo passe novamente por um processo de avaliação quando for testado em outro local.

Muitas variáveis obtidas através de sensoriamento remoto podem ser úteis para a construção de modelos empíricos e o avanço da computação, ferramentas estatísticas e de “machine learning”, tem melhorado a geração e avaliação da modelagem empírica, porém o desempenho destas ferramentas ainda é pouco conhecido (ZANDLER et al., 2015). No sensoriamento remoto, os modelos empíricos se baseiam principalmente na seleção de bandas espectrais ou índices de vegetação com elevada correlação com a produção da biomassa forrageira (VERRELST et al., 2010). Embora uma grande quantidade de bandas espectrais possa trazer benefícios para algumas aplicações do sensoriamento remoto em estudos sobre vegetação, o grande desafio é lidar com a multicolinearidade espectral (VERRELST et al., 2019).

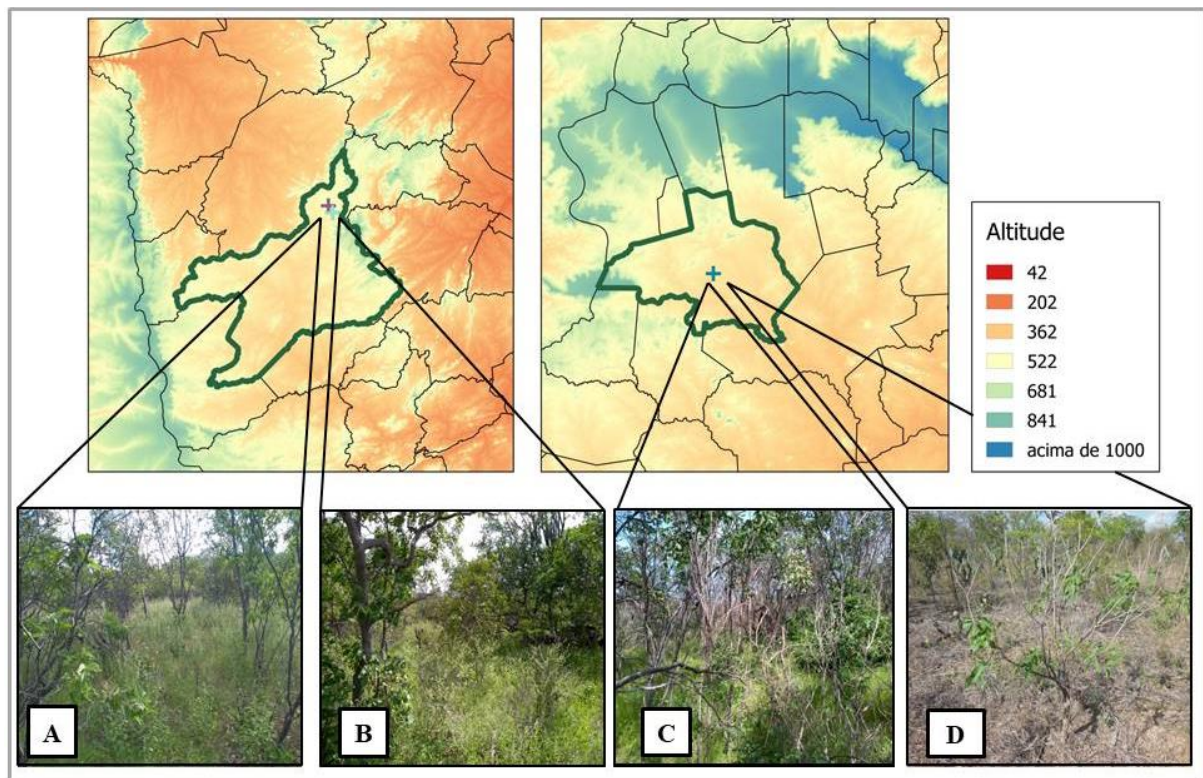
Os modelos mecanicistas são os que se baseiam no envolvimento de leis da física, da química e da biologia nos processos de produção da vegetação, sendo mais adequado do que os modelos empíricos, por ser construído com base na estrutura do sistema, dividindo o sistema em componentes e tentando entender o comportamento todo, em termos das respostas dos componentes individuais e suas interrelações (LARA & RAKOCEVIC, 2014). O modelo PHYGROW é um modelo mecanicista que tem sido utilizado em projetos de alerta precoce e no desenvolvimento de sistemas de monitoramento de produção de forragem em diversas regiões áridas e semiáridas do mundo, como no Quênia (MATERE et al., 2019), na Mongólia (ANGERER, 2012) e nos Estados Unidos (ANGERER, 2008) Apesar de ser um modelo bastante aplicado em vegetações nativas do mundo, não há estudos que tenham medido a capacidade do modelo PHYGROW em simular a biomassa forrageira em pastagens nativas da Caatinga. Com base no exposto, o objetivo deste estudo foi avaliar o desempenho de modelo empírico e mecanicista para simulação da biomassa de pastagem nativa da Caatinga, assim como aplicar a modelagem empírica para confecção de mapas de produção de forragem como proposta a uma ferramenta auxiliar a produção pecuária nesta região.

## 4.2 MATERIAL E MÉTODOS

### 4.2.1 Localização e caracterização climática da área experimental

Para obtenção dos dados de campo foram estabelecidos transetos permanentes nos municípios de Tauá e Ouricuri, localizados nos Estados do Ceará e Pernambuco, respectivamente. Foram estabelecidos dois transetos em Tauá (Figura 19A) e dois transetos em Ouricuri (Figura 19B).

Figura 19 - Limites geográficos dos municípios de Tauá e Ouricuri e os transetos permanentes com diferentes densidades da vegetação lenhosa em Tauá (A e B) e Ouricuri (C e D).



Fonte. Elaborado pelo autor.

Foram monitorados durante dois anos quatro sítios ecológicos que consistem em transetos permanentes, sendo que dois estão localizados na fazenda Cachoeirinha do Pai Senhor (Latitude  $-5.62^{\circ}$  S e Longitude  $-40.12^{\circ}$  W), pertencentes ao distrito Barra Nova, município de Tauá, no Ceará, e os dois em Ouricuri, Pernambuco (Latitude  $-7.97^{\circ}$  S e Longitude  $-40.15^{\circ}$  W). Segundo o Instituto de Pesquisa e Estratégia Econômica do Ceará (2017), as características de Tauá a classificam como uma região tropical quente semiárida de acordo com Köppen (Tabela 8), e a vegetação predominante é do tipo Floresta Caducifolia

Espinhosa e Caatinga Arbustiva Aberta.

Tabela 8. Dados climáticos dos municípios localizados os sítios ecológicos para coleta de biomassa de forragem no campo (dados históricos do INMET - 2000 a 2020)

Estado	Município	Precipitação (mm)	Temperatura (°C)		
			Max	Med	Min
Ceará	Tauá	503,0±180	31,8±2,1	25,3±1,8	21,2±2,5
Pernambuco	Ouricuri	564,8±206	32,0±1,7	26,8±2,2	20,0±1,3


Já o município de Ouricuri se localiza numa unidade que apresenta distinção climática em função da altitude, ou seja, áreas de ameno nas cotas mais altas e áreas mais quentes nos sopés e encostas das serras e maciços com período chuvoso de janeiro a maio com vegetação predominantemente de Floresta Caducifólia e Caatinga Hipoxerófila (BELTRÃO et al., 2005).

#### 4.2.2 Avaliação da vegetação

Foram estabelecidos transetos permanentes do tipo quadrantes com forma de cruz, com 25 m de comprimento para cada lado a partir do centro. Após a escolha para estabelecimento dos transetos, realizou-se a poligonal da área da pesquisa com a obtenção dos limites através de pontos de controle terrestre por GPS de navegação Garmim Etrex 10, que foram em sequência processados na ferramenta Google Earth Pro (Figura 20A e 20B).

Foi caracterizada a densidade arbustivo-arbórea das áreas com análise da densidade total por meio da contagem das plantas arbustivas e arbóreas em cada quadrante dos transetos. Após a definição da densidade foi definido que cada vegetação receberia a designação correspondente a sua densidade total de plantas lenhosas, em que: 144 plantas/ha, em Tauá, seria denominada de Caatinga TD144, Tauá com densidade de 280 plantas/ha de Caatinga TD280, Ouricuri com densidade de 212 plantas/ha de Caatinga OD212 e Ouricuri com densidade de 372 plantas/ha de Caatinga OD372.

Figura 20 - Transeito permanente do tipo quadrante (A), e suas dimensões (B), moldura utilizada para colheita da biomassa herbácea de 0,25 m<sup>2</sup> (C) e moldura utilizada para colheita da biomassa lenhosa de 20 m<sup>2</sup> (D)



Fonte: Elaborado pelo autor.

A biomassa de forragem proveniente do estrato herbáceo da vegetação foi mensurada através do corte de toda forragem presente em uma moldura de 0,25 m<sup>2</sup> (dimensões de 1 m de comprimento por 0,25 m de largura) que foi lançada duas vezes em cada direção do transeito, perfazendo oito pontos por coleta (Figura 20C). Então, a biomassa herbácea localizada na moldura foi cortada rente ao solo. Para amostragem da biomassa do estrato lenhoso e arbustivo foram estabelecidas molduras de 20 m<sup>2</sup> (2 x 10 m) em cada quadrante do transeito, onde foi amostrada a biomassa de cada planta referente a esse estrato pelo método da unidade referencial (Figura 20D). Este método consiste na escolha de três galhos de cada planta lenhosa presente na moldura, que representem uma unidade referencial. O restante da biomassa da planta foi estimada através da contagem de quantas unidades referenciais há na planta até a altura de 2 m.

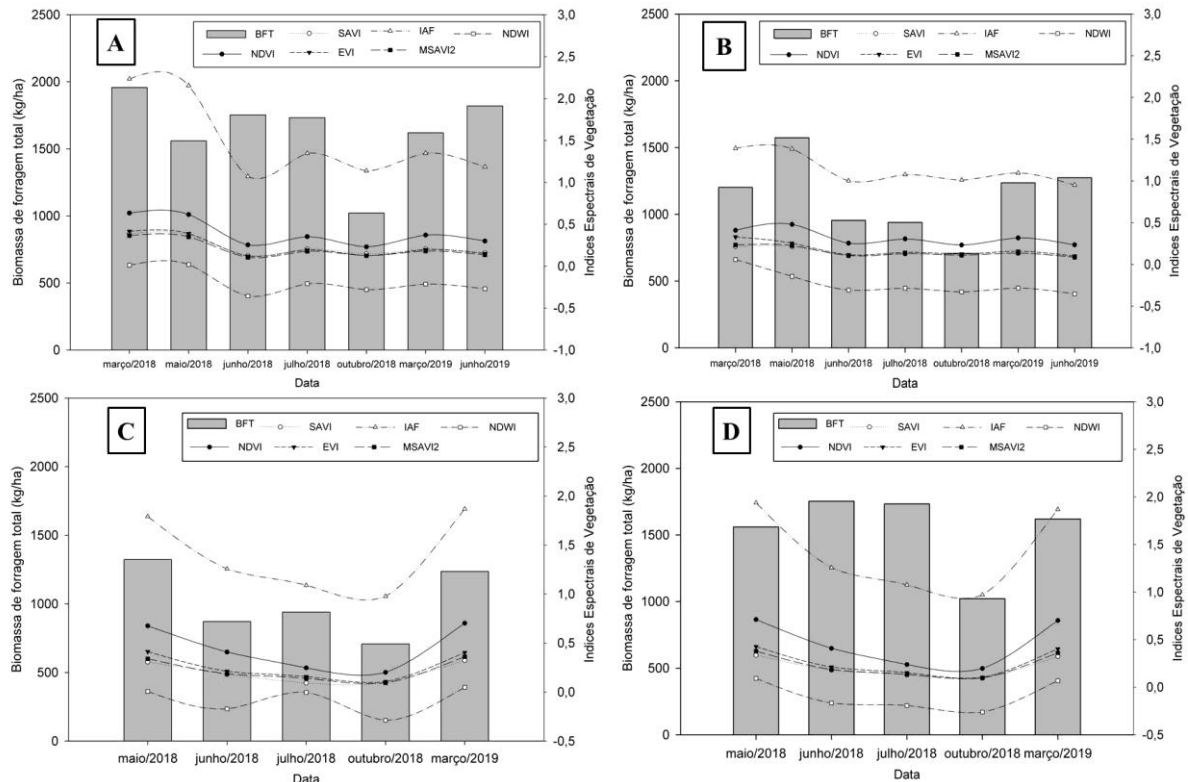
A forragem cortada nas molduras foi levada ao laboratório e, em seguida, as amostras foram encaminhadas para estufa de circulação forçada de ar a 65 °C até atingir peso constante, para a obtenção da massa pré-seca. Após a secagem em estufa, as amostras foram

pesadas em balança digital e a biomassa de forragem total obtida através da soma da biomassa proveniente do estrato herbáceo e da vegetação lenhosa.

#### 4.2.3 Geração de modelos empíricos a partir de dados de sensoriamento remoto

Para o desenvolvimento dos modelos empíricos de simulação da biomassa forrageira por sensoriamento remoto, foram obtidas imagens do satélite Sentinel-2A junto à plataforma Earth Explorer, nas datas mais próximas das coletas *in loco* das amostras. Os procedimentos para a realização do pré-processamento de correção atmosférica das imagens, a álgebra de mapas para obtenção dos índices espectrais de vegetação e suas respectivas fórmulas são os mesmos já descritos no Capítulo 2 (Para mais informações, veja o Capítulo 2). Após a obtenção dos índices espectrais de vegetação, os mesmos foram pareados aos dados de biomassa de cada quadrante e utilizados na criação de modelos empíricos não lineares (Figura 21).

Figura 21 - Biomassa de forragem total e índices espectrais de vegetação (NDVI, SAVI, EVI, IAF, MSAVI<sub>2</sub> e NDWI) obtidos a partir de dados Sentinel 2-A colhidos em vegetações nativas do bioma Caatinga. Vegetações: TD144 (A) e TD280 (B) OD372 (C) e TD212 (D).



Fonte: Elaborado pelo autor.



Para a geração dos modelos empíricos foi utilizado o programa LAB Fit Curve Fitting (SILVA et al., 2004), que realiza o ajuste de funções com aplicação de uma série de modelos não lineares, e apresenta informações estatísticas básicas sobre o desempenho do modelo em estimar o valor real de biomassa. Há cerca de 280 funções no banco de dados do LABFit, de modo que as 10 equações matemáticas mais ajustadas aos dados são selecionadas por estimativas do qui-quadrado (VIDYULLATHA & RAO, 2016).

#### **4.2.4 Calibração do modelo PHYGROW**

A calibração foi realizada na plataforma virtual do modelo PHYGROW (PHYWEB). O PHYGROW simula a produção de biomassa considerando condições ideais para o crescimento vegetal e, após isso, desconta o crescimento das plantas com base no nível de estresse hídrico, estresse por temperatura e a demanda pelos animais em pastejo (MATERE et al., 2019). Para realizar a parametrização do modelo PHYGROW, coletou-se dados de cobertura da vegetação e composição botânica das espécies de plantas (RHODES et al., 2014). Para isso foi determinada a porcentagem de cobertura de solo referente à presença de monocotiledôneas, dicotiledôneas, serrapilheira e rochas pelo método visual, e inseridas como variável de composição da comunidade vegetal no modelo PHYGROW.

O modelo simula o crescimento das plantas considerando condições hídricas não limitantes descontando o crescimento vegetal de acordo com a magnitude do estresse hídrico e térmico e na demanda por animais em pastejo (ANGERER, 2012). O modelo PHYGROW contém parâmetros para informações da superfície e da camada do solo, das espécies e da comunidade vegetal, do manejo de pastagens e das taxas de lotação, sendo conduzido através de um banco de dados climáticos diários (STUTH et al., 2003).

O subcomponente vegetal foi subdividido em três grupos funcionais (monocotiledôneas, dicotiledôneas herbáceas e plantas lenhosas) obtidos por meio da análise de cobertura de cada grupo funcional. Também foram inseridos os parâmetros de crescimento dos grupos funcionais específicos, incluindo índice de área foliar, taxa de crescimento relativo, renovação da folha, profundidade de raiz, altura da planta e temperaturas ideais para o crescimento vegetal. Após a caracterização inicial dos dois sítios ecológicos, estes foram visitados periodicamente para a realização das colheitas de biomassa forrageira para os processos de calibração e validação do modelo. A Tabela 9 apresenta as espécies encontradas nos sítios ecológicos com diferentes coberturas lenhosas e seus respectivos grupos funcionais e os principais parâmetros adicionados durante o processo de parametrização do modelo.

Tabela 9. Cobertura de monocotiledôneas, dicotiledôneas, serrapilheira e rochas, expressas em % e informações adicionais dos grupos funcionais para fins de parametrização do modelo PHYGROW

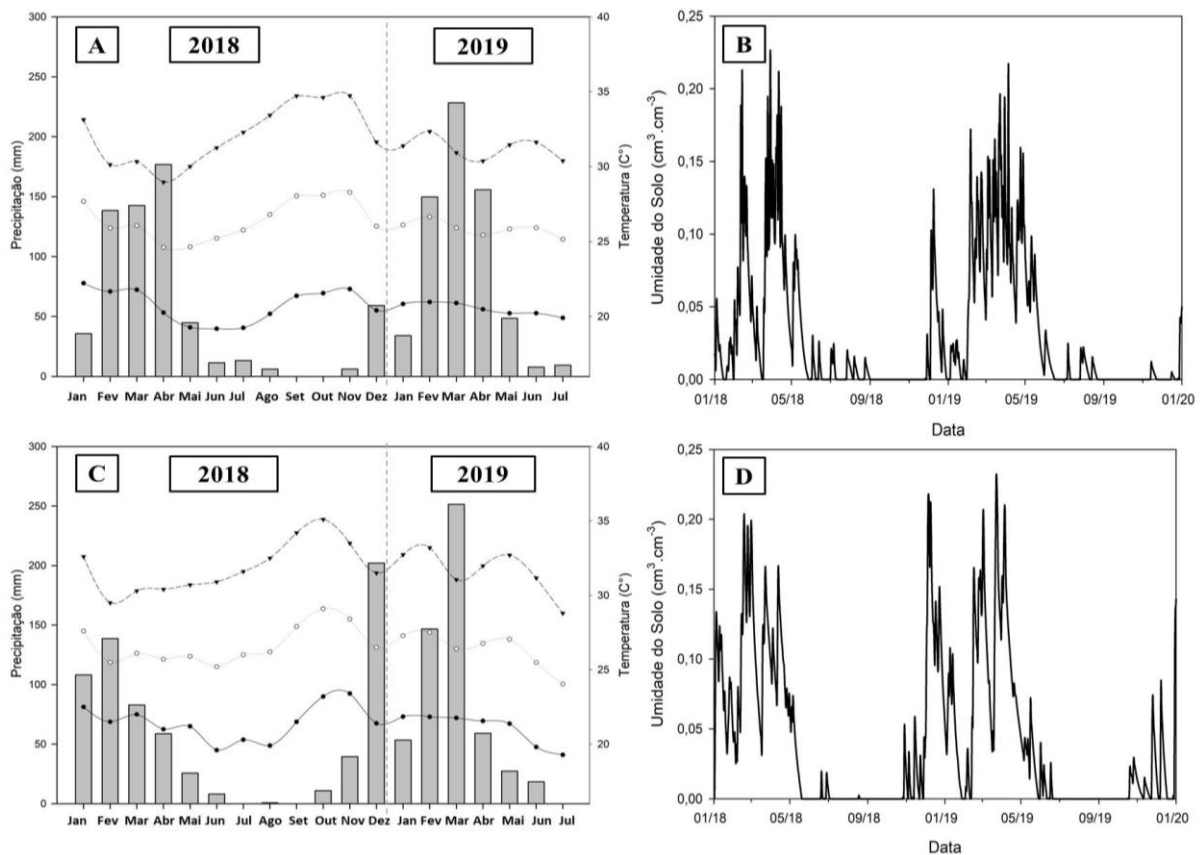
Transeto	Cobertura (%)				
	Monocotiledôneas	Dicotiledôneas	Arbustivo-arboreo	Solo	Serrapilheira
Caatinga TD144	30	30	15	10	15
Caatinga TD280	20	20	30	10	20
Caatinga OD212	10	38	20	30	12
Caatinga OD372	26	44	40	30	10

Grupo Funcional	Parâmetros PHYGROW			
	IAF	Altura (cm)	Máxima biomassa	Sistema radicular
Monocotiledôneas	1,80	50	1100	40
Dicotiledôneas	1,51	50	1000	40
Arbusto-Arbóreo	2,21	200	250	60

Por fim, o subcomponente clima possui seis variáveis que incluem ano, dia, temperatura máxima e mínima, chuva e radiação solar. Para parametrização da precipitação o PHYWEB é alimentado diariamente com dados de precipitação CHIRPS (Figura 22A e C).

Figura 22 - Precipitação média mensal (mm), temperatura máxima, média e mínima (°C) e umidade do solo durante o período de coletas de dados no campo (2018-2019) em Tauá (A-B) e Ouricuri (C-D). Dados obtidos na plataforma PHYWEB





Fonte: Elaborado pelo autor.

A temperatura máxima, a mínima e a precipitação são obtidas com a inserção da latitude e longitude do local de monitoramento para adição do clima no modelo de simulação e executado para cada local. O período chuvoso está compreendido principalmente entre fevereiro e abril, e período seco de maio a janeiro. Então, o modelo se baseia nas informações sobre o solo e o clima local gerando uma variação da umidade do solo ao longo do ano, de modo que esta terá relação direta com a estacionalidade da produção de forragem simulada (Figura 22B e D).

A contabilidade do balanço hídrico do solo inclui características de interceptação de água, escoamento, evaporação, infiltração, percolação, transpiração, e drenagem profunda, os quais tornam-se processos utilizados para simular a água disponível, ou indisponível para plantar raízes. O modelo PHYGROW acomoda um número ilimitado de camadas de solo ( $k \leq n$ ) para delinear diferenças na textura do solo, condutividade hidráulica saturada, capacidade de campo, e fator de rocha (STUTH et al., 2003).

O subcomponente de pastejo do modelo possui 19 variáveis relacionadas à cada tipo/classe de animal em pastejo, incluindo ingestão de forragem, taxa de lotação e preferência de pastejo para cada espécie de planta. O subcomponente do solo possui 13 parâmetros que incluem variáveis de profundidade do solo, densidade do solo, infiltração e retenção de água. Para fim de obtenção das características do solo, foram realizadas colheitas de amostras da camada superficial (0-20 cm) durante o estabelecimento inicial dos transetos para auxiliar na parametrização do subcomponente solo.

Na etapa de calibração, foram preenchidos os parâmetros dos subcomponentes do modelo e realizada a simulação, para posteriormente verificar as diferenças entre os valores obtidos via simulação e os valores de biomassa colhidos no campo. Foram realizadas as calibrações do modelo com os ajustes necessários de todos os seus subcomponentes e quando a diferença entre os valores simulados e os colhidos no campo foi menor que o erro padrão da média, o modelo foi considerado calibrado. Após a calibração do modelo, os seus parâmetros não foram mais ajustados e os dados de biomassa restantes foram utilizados na validação do modelo. Durante a etapa de calibração foram utilizados 70% dos dados, que corresponderam a 7 dados de biomassa por cenário, e para validação foram utilizados os restantes 30% dos dados, sendo que foi feita uma única validação com os 12 dados dos 4 locais de monitoramento.

#### **4.2.5 Estatísticas utilizadas para avaliação dos modelos de simulação**

Inicialmente, foi realizada a análise de normalidade dos dados e partindo do princípio que os dados não apresentaram distribuição normal, foi escolhida a análise de correlação de Spearman para medir a correlação entre a biomassa de forragem e os índices espectrais de vegetação, por meio do pacote CorrPlot (WEI et al., 2017) do Software R Studio, o qual também foi utilizado para a plotagem da matriz de correlação. Para realizar a validação dos modelos, foi utilizado o índice “d” de Willmott (Tabela 10), que varia de zero a um, valor de 1 indica uma acurácia perfeita e 0 indica não haver nenhuma exatidão (WILLMOTT, 1981).

Tabela 10 - Descrição das estatísticas utilizadas para a medida do desempenho dos modelos em simular a produção de biomassa do pasto nativo no bioma Caatinga.

Nome	Formula	Equação
Índice-d de Willmott	$1 - \frac{\sum (Si - Oi)^2}{\sum ([Si - O] + [Oi - O])^2}$	Equação 1
Erro Médio Absoluto	$\frac{\sum_{i=1}^N Si - Oi}{N}$	Equação 2
Porcentagem de Viés	$\frac{Si - Oi}{N}$	Equação 3
RMSE	$\sqrt{\frac{\sum_{i=1}^N (Oi - Si)^2}{N}}$	Equação 4

Para todas as equações descritas acima: O Si é o i-ésimo valor proveniente da simulação; o Oi é o i-ésimo valor observado e N é o número de pares de dados simulados e observados.

Foi utilizado o erro médio absoluto (“mean absolute error” - MAE), para verificar a tendência do modelo em simular a biomassa com relação aos valores observados (equação 2). A porcentagem de viés (equação 2), que possui valor ótimo igual a zero, com valores de baixa magnitude indicando boa acurácia, valores positivos indicam superestimação do modelo e negativos indicam subestimação do modelo. A raiz quadrada do erro médio (“Root mean square error” - RMSE) verifica a magnitude da diferença entre a biomassa simulada e a biomassa observada (equação 4). Além disso, foi efetuada a análise de regressão entre os valores observados e simulados com o objetivo de verificar a precisão do modelo. Os índices para o processo de avaliação foram obtidos por meio do pacote hydroGOF do *software* R (R CORE TEAM, 2019) e apresentados por métodos gráficos e numéricos com auxílio do *software* Sigma Plot (versão 11.0).

#### 4.2.6 Mapas de produção de forragem

Os mapas de produção de forragem foram gerados por meio da plataforma Google Earth Engine (GEE) e do Software QGIS (2.18). Para realizar a escolha do índice espectral de


vegetação utilizado na confecção dos mapas, foram consideradas as medidas de desempenho dos modelos empíricos durante a etapa de validação, bem como a correlação dos índices com a biomassa de forragem por meio da análise da correlação de Spearman. Após a escolha do índice mais adequado para a produção dos mapas, foi gerado um mosaico trimestral de imagens Sentinel-2 A e, posteriormente, a aplicação do modelo empírico ocorreu através de álgebra de mapas na plataforma GEE. Em sequência à aplicação dos modelos, foram gerados os mapas de produção de forragem, que foram exportados da plataforma Google Earth Engine para a obtenção do layout final dos mapas temáticos por meio do programa QGIS (2.18).

### 4.3 Resultados E Discussão

#### 4.3.1 Geração e validação de modelos empíricos

O SAVI foi o índice que apresentou a maior correlação Spearman ( $r$  0,47;  $P < 0,01$ ) com a biomassa de forragem (Figura 23), seguido pelo IAF ( $r$  0,45;  $P < 0,01$ ), enquanto o NDWI apresentou a menor correlação ( $r$  0,26;  $P < 0,01$ ) com a biomassa de forragem.

Figura 23 - Correlação de Spearman entre a biomassa de forragem colhida em pastos nativos da Caatinga e os índices espectrais de vegetação

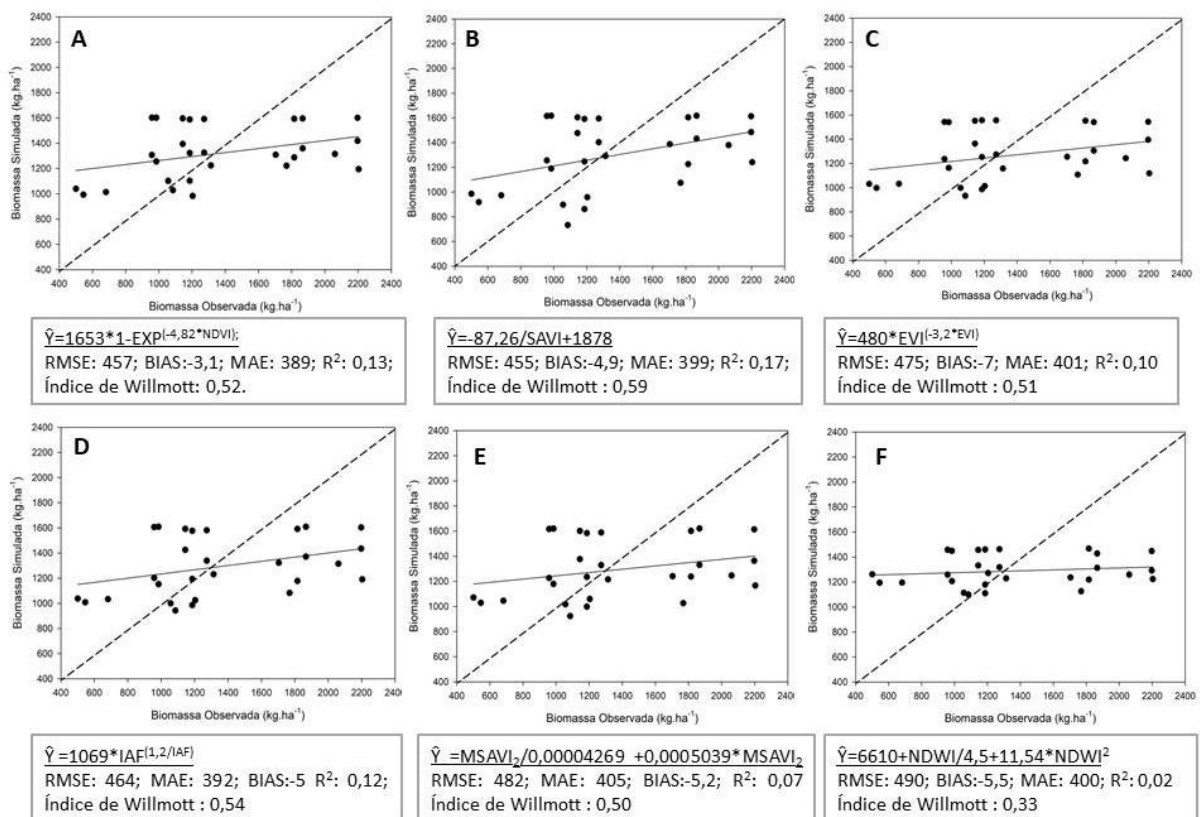


Fonte: Elaborado pelo autor.

O NDVI é o índice mais utilizado para relacionar parâmetros biofísicos de vegetações, porém em algumas situações de vegetação ele tende à saturação em função dos ruídos

atmosféricos superestimam os valores de biomassa (LU et al., 2014). Então, alguns índices, como o SAVI, foram desenvolvidos com o intuito de substituir o NDVI pela presença de parâmetros de correção das influências atmosféricas e da exposição do solo (KARNIELI et al., 2013). Em vegetação de Caatinga, são poucos os estudos que avaliaram a eficiência do SAVI via sensoriamento remoto para estimar a biomassa de pastagens naturais, mas já é descrito na literatura que este índice é um importante parâmetro para controlar processos biológicos e físicos da vegetação (GALVÍNCIO et al., 2013), como fotossíntese, evapotranspiração, interceptação da precipitação e fluxo de carbono (SHA et al., 2019). Na validação dos modelos, o índice SAVI (Figura 24) apresentou os melhores ajustes devido ao menor valor de RMSE (455 kg.ha<sup>-1</sup>) e ao maior R<sup>2</sup> (0,17), enquanto o modelo que utilizou o NDVI apresentou menores valores de porcentagem de viés e erro médio absoluto, quando comparado aos demais modelos.

Figura 24 - Modelos empíricos para simulação da biomassa de forragem total com base em índices de espectrais de vegetação obtidos de imagens do Sentinel-2A e dados de campo colhidos em Tauá e Ouricuri.



Fonte: Elaborado pelo autor.

A validação dos modelos mostrou uma tendência de subestimativa da BF, obtida através

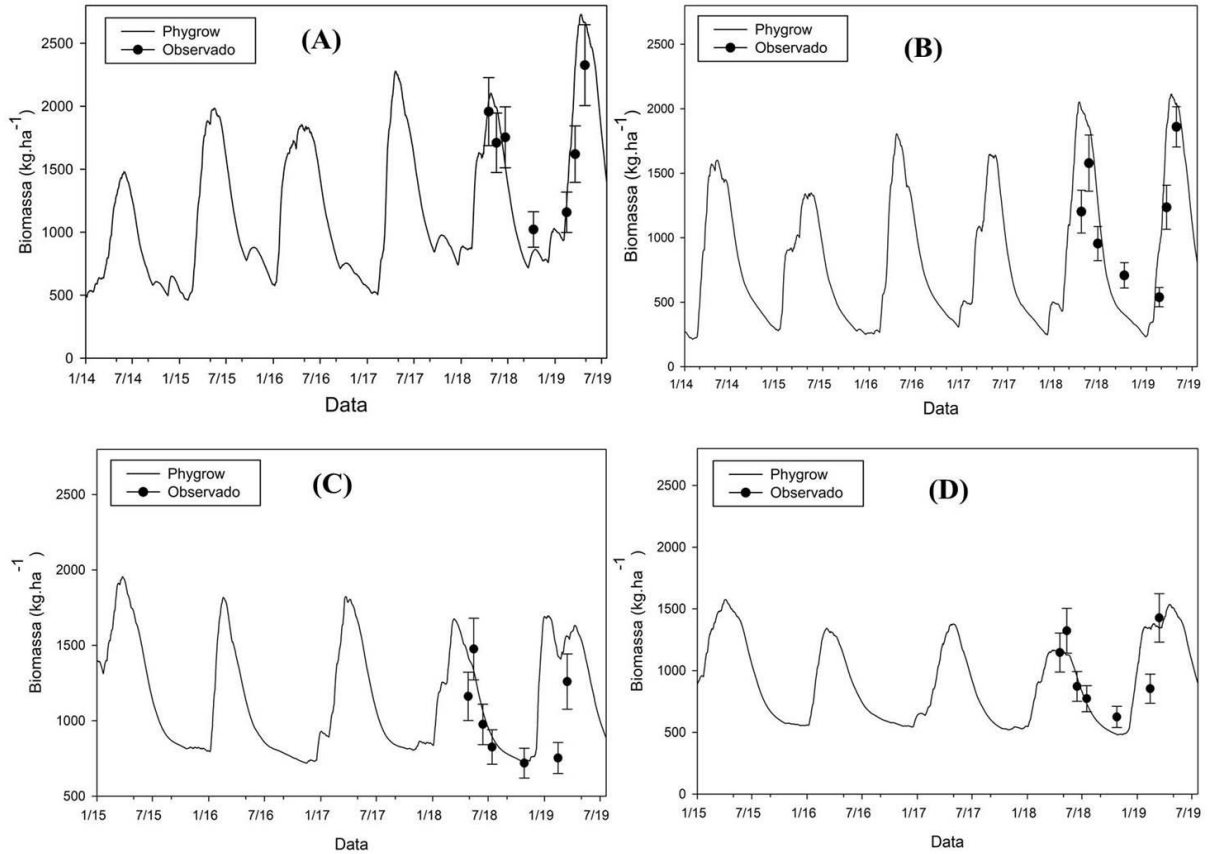
dos valores negativos de percentual de viés para todos os índices de vegetação. Quando o modelo subestima os valores de BF, pode ocorrer o sub pastejo na área e, segundo Reis et al., (2009), nessa condição há maior oportunidade de os animais selecionarem as melhores forrageiras na pastagem. Porém, mesmo que o subpastejo permita um máximo ganho por animal, o ideal é que a taxa de lotação esteja bem ajustada, evitando desperdícios de forragem e otimizando a utilização do fator terra. Os baixos valores para  $R^2$  indicam que o modelo de simulação não está acurado para simular o valor real.

Não há trabalhos que avaliaram o desempenho de modelos empíricos derivados de índices espectrais de vegetação para simular a biomassa de forragem na Caatinga, mas existem estudos nesse bioma para simulação da biomassa total acima do solo para outros fins, como o trabalho de Francisco et al. (2017), que relataram alto ajuste ( $R^2 = 0,75$ ) entre o NDVI e a biomassa total da vegetação lenhosa acima do solo, levando os autores a propor estimar a biomassa lenhosa através do NDVI proveniente de sensoriamento remoto, com elevada acurácia. Em outro trabalho, Teixeira et al (2016) avaliaram a correlação entre o NDVI, SAVI e IAF e a precipitação em áreas de Caatinga no município de Aiuabas (Ceará) e concluíram que estes índices são ferramentas importantes no estudo do comportamento da vegetação sob as mais diferentes condições climáticas, especialmente em regiões do Semiárido brasileiro, em que as chuvas são mal distribuídas e concentradas em poucos meses do ano.

#### **4.3.2 Calibração e validação do modelo PHYGROW**

A calibração do modelo PHYGROW aos dados de campo de modo geral foi bem sucedida (Figura 25). A Caatinga TD144 (A) apresentou produção de biomassa média de  $1791 \text{ kg}\cdot\text{ha}^{-1}$  e média simulada foi de  $1930 \text{ kg}\cdot\text{ha}^{-1}$ , e a Caatinga TD280 (B) apresentou produção de biomassa média colhida no local foi de  $1357 \text{ kg}\cdot\text{ha}^{-1}$  e biomassa média simulada  $1535 \text{ kg}\cdot\text{ha}^{-1}$ . A vegetação OD212 (C) apresentou produção de biomassa média colhida no local foi de  $1024 \text{ kg}\cdot\text{ha}^{-1}$  e biomassa média simulada de  $1204 \text{ kg}\cdot\text{ha}^{-1}$ , enquanto a vegetação OD372 (D) apresentou produção de biomassa média de  $1002 \text{ kg}\cdot\text{ha}^{-1}$  e a média simulada foi de  $1021 \text{ kg}\cdot\text{ha}^{-1}$ . Para todas as vegetações, as maiores médias obtidas nas simulações mostraram tendência do modelo em superestimar os valores reais de biomassa.

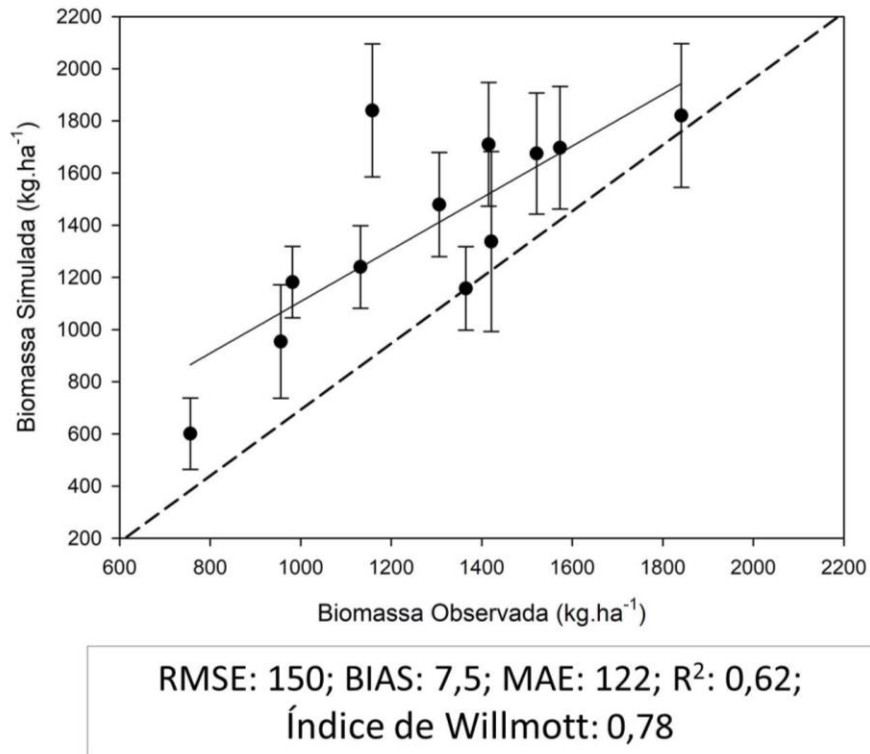
Figura 25 - Curva de simulação de biomassa obtida por meio do modelo PHYGROW ( $\text{kg}\cdot\text{ha}^{-1}$  de MS) em vegetações de Caatinga com diferente densidade lenhosa: TD144 (A) e TD280 (B) OD212 (C) e TD372 (D) (●) Dados coletados em campo (2018 e 2019).



Fonte: Elaborado pelo autor.

As curvas de simulação mostram que existe uma tendência do modelo em superestimar os valores reais de biomassa no início do período chuvoso, muito possivelmente devido haver superestimativa do parâmetro precipitação o qual é obtido por meio da estimativa CHIRPS. A validação do modelo PHYGROW apresentou superestimativa da biomassa de forragem, com viés de 7,5% (Figura 26). Apesar dessa superestimativa, a RMSE de  $150 \text{ kg}\cdot\text{ha}^{-1}$ , o índice-d de Wilmott 0,78 e o  $R^2$  de 0,68 indicam que o modelo possui boa capacidade de simular os valores de biomassa de forragem da Caatinga. Segundo Tedeschi (2005), a avaliação do modelo através da validação é uma etapa fundamental para indicar o nível de precisão e acurácia das suas previsões, tornando-a uma etapa indispensável, pois aumenta a confiabilidade nas estimativas obtidas pelo modelo.

Figura 26 - Comparação dos valores observados com os simulados pelo modelo PHYGROW ( $\text{kg}\cdot\text{ha}^{-1}$ ) durante a validação. (●) Dados coletados em campo e as barras correspondem ao erro padrão.



Fonte: Elaborado pelo autor.

Com relação à aplicação do modelo PHYGROW em vegetações nativas, Angerer (2008) avaliou o modelo PHYGROW na fase de calibração para prever a biomassa herbácea em pastagens nativas de uma região semiárida do Texas e obteve correspondência de 0,72 durante a análise de regressão linear dos valores simulados com os valores observados e eficiência da estimativa de 0,58. A partir destes valores, o autor classificou o modelo com uma habilidade de moderada a boa para prever a biomassa naquele local. Kaitho et al. (2007) avaliaram o modelo PHYGROW em regiões da África Oriental e obtiveram uma correspondência de 96% na análise da regressão linear, com um erro padrão de previsão de  $161 \text{ kg}\cdot\text{ha}^{-1}$ .

Neste estudo, os resultados obtidos na validação demonstraram uma alta capacidade do modelo PHYGROW em simular a biomassa de forragem, podendo ser uma ferramenta útil no planejamento das propriedades, principalmente através da realização do monitoramento frequente desta variável para fins de ajuste da taxa de lotação. Além disso, os modelos de simulação podem verificar antecipadamente os efeitos das mudanças climáticas sobre os sistemas de produção (TIETJEN; JELTSCH, 2007).

O desenvolvimento e aperfeiçoamento de metodologias baseadas na modelagem podem auxiliar os pecuaristas no ajuste da taxa de lotação das pastagens, bem como servir como base para o desenvolvimento de políticas públicas. Mesmo sabendo da importância da disseminação do conhecimento sobre modelagem na simulação, são poucos os estudos que avaliaram a aplicação de modelos em pastagens nativas (ANDRADE et al., 2015), o que pode ser explicado pela falta de compreensão das capacidades e limitações do uso da modelagem, além da pouca experiência na avaliação, calibração e uso de modelos (MARIN; JONES, 2014). Todavia, independentemente das dificuldades do seu uso, espera-se que esta ferramenta tenha maior utilização, sabendo que os modelos precisam estar bem calibrados, fornecendo informações com uma grande representação, que sejam precisos e tenha alta acurácia na estimativa da biomassa, bem como baixo custo de operação.

#### **4.3.3 Aplicação de modelo empírico na produção de mapas de biomassa de forragem**

Os mapas de biomassa (Figura 8) para os municípios de Ouricuri (A) e Tauá (B) obtidos trimestralmente durante os anos de 2018 e 2019 foram produzidos através da aplicação do modelo:

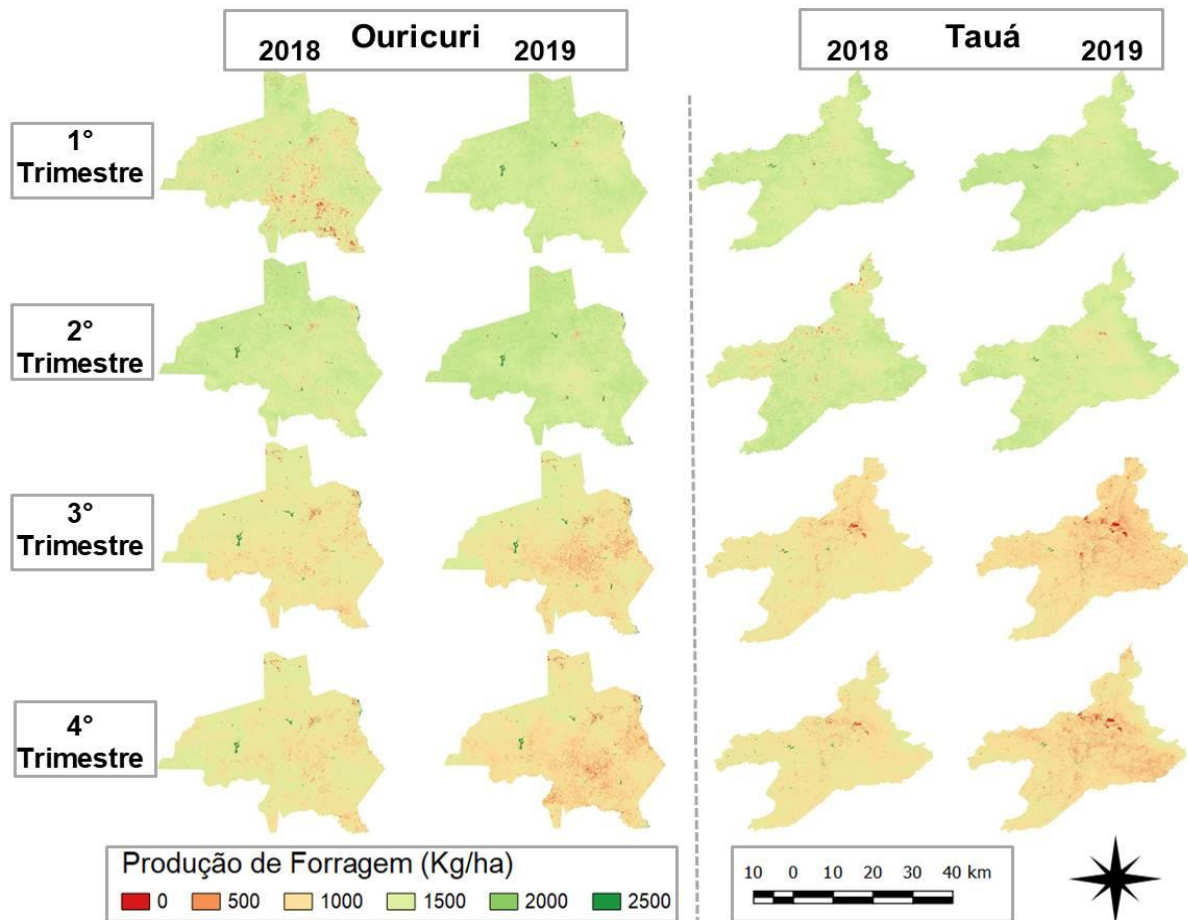
$$\hat{Y} = \frac{-87,26}{SAVI} + 1878$$

O modelo que utilizou o SAVI como parâmetro para estimativa da BF apresentou o melhor desempenho na etapa de validação, bem como este índice apresentou a maior correlação de Spearman com os dados de BF, sendo considerado o modelo mais confiável para a produção dos respectivos mapas. Analisando-os (Figura 27), nota-se a variação da BF ao longo do ano, destacando-se maior proporção de áreas com elevada BF no 1º e 2º trimestre de cada ano (> 2.000 kg/ha).

O intuito da confecção de tais mapas é auxiliar os pecuaristas com a estimativa da BF local, possibilitando o ajuste de uma taxa de lotação sustentável na propriedade, evitando futuros problemas de subpastejo ou sobrepastejo. Além disso, o ajuste da taxa de lotação adequado ao longo do ano fornece subsídios ao pecuarista para prevenir a degradação da Caatinga, por auxiliar no uso sustentável da sua vegetação.



Figura 27 - Mapas de produção de forragem para os municípios de Ouricuri (A) e Tauá (B) obtidos trimestralmente durante os anos de 2018 e 2019.



Fonte: Elaborado pelo autor.

Sabe-se que as mudanças climáticas e o uso insustentável da Caatinga aumentam as incertezas e os riscos da produção animal neste bioma, principalmente devido à variabilidade climática resultar em excedentes ou déficits de biomassa de forragem. Segundo Angerer (2012), a capacidade de caracterizar os impactos que a seca causa sobre a produção animal está associada ao gerenciamento dos riscos de produção, sendo um grande problema enfrentado pelo pecuarista, principalmente, devido à dificuldade em realizar avaliações precisas de produtividade das pastagens nativas. Além disso, são escassos os estudos que desenvolvem metodologias para caracterização da vegetação da Caatinga em grande escala, bem como os que realizam a previsão da condição da vegetação em termos de produção de forragem e a partir desta proponham o ajuste taxa de lotação e/ou conservação de forragem excedente daquele para períodos futuros de escassez, ou para comercialização.

## **CONCLUSÃO**

Os modelos empíricos provenientes de dados de sensoriamento remoto associados a dados colhidos no campo apresentam baixa capacidade de simular a biomassa de forragem na Caatinga, pela influência de plantas lenhosas e principalmente de sua porção não colhida pelos herbívoros domésticos.

A geração de mapas de biomassa de forragem a partir dos modelos empíricos contribui com informações relevantes e complementares da sua oscilação com o tempo e previsão de possíveis desastres causados pelas secas.

O modelo PHYGROW apresenta os melhores índices de desempenho de validação, sendo mais indicado como ferramenta para estimar a biomassa de forragem em Caatingas com diferentes densidades lenhosas, tornando-se uma ferramenta útil para o manejo sustentável de pastagens nativas.

## 5. CONSIDERAÇÕES FINAIS E IMPLICAÇÕES

O desenvolvimento e aperfeiçoamento de ferramentas baseadas em sensoriamento remoto e modelagem mostraram ser muito promissoras para monitorar a estacionalidade da produção forrageira nas vegetações nativas da Caatinga, podendo ser muito úteis em compor informações de alerta precoce para os rebanhos. Importante destacar que as metodologias sugeridas neste trabalho auxiliarão principalmente os pequenos produtores situados em regiões do bioma Caatinga, pois estes representam a maior proporção entre os pecuaristas da região.

Os resultados mostraram alta eficiência no monitoramento das condições da vegetação de Caatinga por meio do estudo da análise da mudança da cobertura do solo e pelo monitoramento das regiões mais propensas à incidência de secas através de mapas de NDVI e NDDI, sugerindo ser um método que servirá de apoio ao governo no desenvolvimento de políticas públicas com enfoque na preservação do bioma Caatinga, bem como na produção e distribuição frequente de alertas com a localização das regiões mais propícias a desastres ambientais por incidência de secas. Além disso, a análise da distribuição dos rebanhos por meio do geoprocessamento localizou as regiões de maior potencial para investimentos em caprinocultura, ovinocultura e/ou bovinocultura, bem como qual a espécie animal esta mais preparada para enfrentar as adversidades de épocas mais secas.

Por último, associando todas as ferramentas de modelagem há a criação de um protocolo com tecnologias de auxílio aos pecuaristas para realizar a estimativa de uma taxa de lotação sustentável para as pastagens nativas, evitando o subpastejo ou sobrepastejo da vegetação. Com isso, espera-se reduzir o risco da pecuária nestas regiões, de modo que o produtor tenha como prever épocas de falta ou excesso de produção de forragem, e promover o ajuste da sua taxa de lotação e/ou conservação de forragem excedente.

## REFERÊNCIAS

- AB'SÁBER, Aziz Nacib. **Os domínios de natureza no Brasil: potencialidades paisagísticas**. Ateliê editorial, 2003.
- ADAMS, Richard M. et al. The benefits to Mexican agriculture of an El Niño-southern oscillation (ENSO) early warning system. **Agricultural and Forest Meteorology**, Amsterdam, v. 115, n. 3-4, p. 183-194, 2003.
- ALBUQUERQUE, Ulysses Paulino de; MELO, Felipe PL. Socioecologia da Caatinga. **Ciência e Cultura**, Campinas, v. 70, n. 4, p. 40-44, 2018.
- ALHAMAD, M.N.; STUTH, J.; VANNUCCI, M. Biophysical modelling and NDVI time series to project near-term forage supply: spectral analysis aided by wavelet denoising and ARIMA modelling. **International Journal of Remote Sensing**, Abingdon, v. 28, n. 11, p. 2513-2548, 2007.
- ALLEN, Vivien Gore et al. An international terminology for grazing lands and grazing animals. **Grass and forage science**, Hoboken, v. 66, n. 1, p. 2, 2011.
- ALMEIDA, Alexsandro Claudio dos Santos et al. Simulação do crescimento do capim Tanzânia irrigado com base na unidade fototérmica, na adubação nitrogenada e na disponibilidade hídrica do período. **Acta Scientiarum. Agronomy**, Maringa, 2011, v. 33, n. 2, p. 215-222.
- ALVARADO, Christiam Segundo Morales. **Estudo e implementação de métodos de validação de modelos matemáticos aplicados no desenvolvimento de sistemas de controle de processos industriais**. 2017. Tese de Doutorado. Universidade de São Paulo.
- ANDRADE, A. S. et al. Simulating tropical forage growth and biomass accumulation: an overview of model development and application. **Grass and Forage Science**, Hoboken, v. 71, n.1, pp. 54-65, 2016.
- ANGELOTTI, Francislene; FERNANDES JÚNIOR, P. I.; SA, IB de. Mudanças Climáticas no Semiárido Brasileiro: Medidas de Mitigação e Adaptação. **Revista Brasileira de Geografia Física**, Recife, v. 4, p. 1097-1111, 2011.
- ANGERER, Jay P. Gobi forage livestock Early warning System. **NATIONAL FEED ASSESSMENTS**, p. 115, 2012.
- ANGERER, Jay P.; BIZIMANA, J. C. B.; ALEMAYEHU, Sintayehu. Reducing risk in pastoral regions: the role of early warning and livestock information systems. **Revista Científica de Produção Animal**, Areia, v. 15, n. 1, p. 9-21, 2014.
- ANGERER, Jay Peter. **Examination of high resolution rainfall products and satellite greenness indices for estimating patch and landscape forage biomass**. 2008, pag. 129. PhD Dissertation, Department of Ecosystem Science and Management. College Station, Texas, Texas A&M University.
- ANGERER, Jay Peter. Gobi Forage Livestock Early Warning System. In: **Conducting**

**national feed assessments.** Rome, Italy: Food and Agriculture Organization. v. 15, pp. 115-130, 2012.

ANGERER, Jay Peter. **Phyweb Simulation Modeling Tutorial.** Texas A&M University, Texas A&M AgriLife Research, 2017

AQUINO, Cláudia Maria Sabóia; OLIVEIRA, José Gerardo Beserra. Estudo da dinâmica do Índice de Vegetação por Diferença Normalizada (NDVI) no núcleo de São Raimundo Nonato-PI. **GEOUSP - Espaço e Tempo**, São Paulo, v. 16, n. 2, p. 157-168, 2012.

AQUINO, Deodato do Nascimento et al. Use of remote sensing to identify areas at risk of degradation in the semi-arid region. **Revista Ciência Agronômica**, Fortaleza, v. 49, n. 3, p. 420-429, 2018.

ARAÚJO FILHO, João Ambrosio de. Aspectos zo ecológicos e agropecuários do caprino e do ovino nas regiões semi-áridas. **Embrapa Caprinos e Ovinos-Documents (INFOTEC-A-E)**, 2006.

ARAÚJO FILHO, João Ambrosio. **Manejo pastoril sustentável da caatinga.** v. 01, Cidade Gráfica e Editora Ltda., pp. 200, 2013.

ASRAR, Ghassem et al. Light interception and leaf area estimates from measurements of grass canopy reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, Pasadena, n. 1, p. 76-82, 1986.

ATZBERGER, Clement. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sensing**, Basel, v. 5, n. 2, pp. 949-981, 2013.

BAJGAIN, Rajen et al. Sensitivity analysis of vegetation indices to drought over two tallgrass prairie sites. **ISPRS Journal of Photogrammetry and remote Sensing**, Amsterdam, v. 108, p. 151-160, 2015.

BARBOSA, Humberto Alves et al. Assessment of Caatinga response to drought using Meteorat-SEVIRI Normalized Difference Vegetation Index (2008-2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 1, n. 2, p. 1-18, 2019.

BARROS, Ileana Oliveira; SOARES, Arlete Aparecida. Adaptações anatômicas em folhas de marmeleiro e velame da caatinga brasileira. **Revista Ciência Agronômica**, Fortaleza, v. 44, n. 1, p. 192-198, 2013.

BECERRA, Jorge Alberto Bustamante; SHIMABUKURO, Yosio Edeimar; ALVALÁ, Regina Célia dos Santos. Relação do padrão sazonal da vegetação com a precipitação na região de Cerrado da Amazônia Legal, usando índices espectrais de vegetação. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 24, n. 2, 125-134, 2009.

BECK, Pieter SA et al. Improved monitoring of vegetation dynamics at very high latitudes: A new method using MODIS NDVI. **Remote Sensing of Environment**, Amsterdam, v. 100, n. 3, p. 321 – 334, 2006.

BÉGUÉ, Agnès et al. Remote sensing and cropping practices: A review. **Remote Sensing**, Basel, v. 10, n. 1, p. 99, 2018.

BELTRÃO, Breno Augusto et al. **Projeto cadastro de fontes de abastecimento por água subterrânea**, Estado de Pernambuco: diagnóstico do Município de Ouricuri. CPRM, 2005.

BEUCHLE, René et al. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach. **Applied Geography**, Amsterdam, v. 58, p. 116-127, 2015.

BRASIL. Ministério do Meio Ambiente - MMA. Disponível em: <http://www.mma.gov.br>. Acesso em: 12 out. 2019.

BREIMAN, L. et al. **Classification and regression trees**, Routledge. 2017.

BRYANT, J. R.; SNOW, V. O. Modelling pastoral farm agro-ecosystems: a review. **New Zealand Journal of Agricultural Research**, Abingdon, v. 51, n. 3, p. 349-363, 2008.

BUGGENHOUT, Erik Rodrigues Backx Van. **Análise multivariada de dados do censo agropecuário e distribuição espacial dos rebanhos bovinos**. 2008, pag. 51, Monografia, Departamento de Geografia. Brasília, Universidade de Brasília.

CASTANHO, Andrea DA et al. close look at above ground biomass of a large and heterogeneous Seasonally Dry Tropical Forest-Caatinga in North East of Brazil. **Academia Brasileira de Ciências**, Rio de Janeiro, v. 92, n. 1, 2020.

CAUDURO, Guilherme Fernandes et al. Fluxo de biomassa aérea em azevém anual manejado sob duas intensidades e dois métodos de pastejo. **Revista Brasileira de Zootecnia**, Viçosa, v. 36, n. 2, p. 282-290, 2007.

CEARÁ, GOVERNO DO ESTADO. Instituto de Pesquisa e Estratégia Econômica do Ceará. **Perfil básico municipal**. Fortaleza, 2017.

CECCATO, Pietro et al. Detecting vegetation leaf water content using reflectance in the optical domain. **Remote sensing of environment**, Amsterdam, v. 77, n. 1, p. 22-33, 2001.

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

CHANG, Jinfeng et al. Combining livestock production information in a process-based vegetation model to reconstruct the history of grassland management. **Biogeosciences**, Göttingen, v. 13, n.12, pp. 3757-3776, 2016.

CHAVEZ, Pat S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, Amsterdam, v. 24, n. 3, p. 459-479, 1988.

CHAVEZ, Pat S. Radiometric calibration of Landsat thematic mapper multispectral images. **Photogrammetric Engineering and Remote Sensing**, v. 55, n. 9, p. 1285-1294, 1989.

CONGEDO, Luca. Semi-automatic classification plugin documentation. **Release**, v. 4, n. 0.1,

p. 29, 2016.

COSTA, Julio Cezar et al. Validação dos dados de precipitação estimados pelo CHIRPS para o Brasil. **Revista Brasileira de Climatologia**, Curitiba, v. 24, n.1 p. 228-243, 2019.

COSTA, R. G. et al. Caracterização do sistema de produção caprino e ovino na região Semiárida do estado da Paraíba. Brasil. **Archivos de Zootecnia**, Córdoba, v. 57, n. 218, pp. 195-205, 2008.

DA COSTA ARAÚJO, Daniel Louçana et al. Características morfogênicas, estruturais e padrões demográficos de perfilhos em pastagem de capim-andropógon sob diferentes ofertas de forragem. **Semina: Ciências Agrárias**, Londrina, v. 36, n. 5, p. 3303-3314, 2015.

DA SILVA, Marcos Vinícius et al. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the Brazilian semiarid. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 19, p. 100353, 2020.

DA SILVA, Marisa Maria Venâncio et al. Desafios e paradigmas de convivência com a seca no semiárido. **Biodiversidade, Etnoconhecimento e Produção Sustentável**. Ananindeua: Itacaiúnas, p. 93, 2020.

DE ABREU FARIAS, Manuela; RODRIGUES, Claudinei José; PEREZ, Alondra Beatriz Alvarez. Avaliação do efeito da salinidade na cinética de desoxigenação no ensaio da DBO. **Revista de Ciências Ambientais**, Canoas, v. 13, n. 1, p. 33-41, 2019.

DE FACCIO CARVALHO, Paulo César; BATELLO, Caterina Access to land, livestock production and ecosystem conservation in the Brazilian Campos biome: the natural grasslands dilemma. **Livestock Science**, Amsterdam, v. 120, n. 1-2, p. 158-162, 2009.

DE MORAIS, Leonardo Fiusa et al. Avanços na avaliação de pastagens cultivadas com forrageiras tropicais no Brasil: Uma Revisão. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, Guarapuava, v. 11, n. 2, 2018.

DÍAZ-SOLÍS, H. et al. Adaptive management of stocking rates to reduce effects of drought on cow-calf production systems in semi-arid rangelands. **Agricultural Systems**, Amsterdam, v. 100, n. 1-3, p. 43-50, 2009.

DU, Yun. et al. Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-M Spatial Resolution Produced by Sharpening the SWIR Band. **Remote Sensing**, Basel, v. 8, n. 4, p. 1-19, 2016.

EDVAN, Ricardo Loiola; PINTO, Andréa Pereira. Pecuária como atividade estabilizadora no semiárido brasileiro. **Veterinária e Zootecnia**, Botucatu, v. 13, p. 9, 2013.

FERREIRA, Laerte Guimarães; FERREIRA, Nilson Clementino; FERREIRA, Manuel Eduardo. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, Maringa, v. 30, n. 4, p. 379-390, 2008.

FORKUOR, Gerald et al. Landsat-8 vs. Sentinel-2: examining the added value of sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. **GIScience & Remote**

**Sensing**, Abingdon, v. 55, n. 3, p. 331-354, 2017.

FRAKE, April N. et al. Leveraging big data for public health: Mapping malaria vector suitability in Malawi with Google Earth Engine. **PLoS one**, San Francisco, v. 15, e0235697, 2020.

FRANCISCO, Paulo Roberto Megna et al. Umidade antecedente e índice de vegetação da diferença normalizada no mapeamento da caatinga. **Agropecuária Científica no Semiárido**, Campina Grande, v. 13, n. 2, p. 82-91, 2017.

FUNK, Chris et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific data**, v. 2, n. 1, p. 1-21, 2015.

GALVÍNCIO, Josiclêda Domiciano et al. LAI Improved to Dry Forest in Semiarid of the Brazil. **International Journal of Remote Sensing Applications**, v. 3, n.4, p. 193-202, 2013.

GANEM, Khalil Ali et al. Comparação entre dados com e sem correção atmosférica na classificação da cobertura da Terra de uma área da Caatinga utilizando o Google Earth Engine. **Revista Brasileira de Cartografia**, Monte Carmelo, v. 69, n. 6, 2017.

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, Amsterdam, v. 58, n. 3, p. 257-266, 1996.

GEIST, Helmut J.; LAMBIN, Eric F. Dynamic causal patterns of desertification. **Bioscience**, Oxford, v. 54, n. 9, p. 817-829, 2004.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, Amsterdam, v. 202, p. 18–27, 2017.

GU, Yingxin et al. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, Washington, v. 34, p. 1-6, 2007.

GUNES, Funda. Penalized regression methods for linear models in SAS/STAT®. In: Proceedings of the SAS Global Forum 2015 Conference. Cary, NC: SAS Institute Inc. [http://support.sas.com/rnd/app/stat/papers/2015/PenalizedRegression\\_LinearModels.pdf](http://support.sas.com/rnd/app/stat/papers/2015/PenalizedRegression_LinearModels.pdf). 2015.

GUTIÉRREZ, Ana Paula A. et al. Drought preparedness in Brazil. **Weather and Climate Extremes**, v. 3, n. 6, p. 95-106, 2014.

HATFIELD, Jerry L. et al. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, Madison, v. 100, n. 3, p. 117, 2008..

HE, Chunyang et al. Zoning grassland protection area using remote sensing and cellular automata modeling—A case study in Xilingol steppe grassland in northern China. **Journal of Arid Environments**, Londres, v. 63, n. 4, p. 814-826, 2005.

HERMANCE, John F.; AUGUSTINE, David J.; DERNER, Justin D. Quantifying



characteristic growth dynamics in a semi-arid grassland ecosystem by predicting short-term NDVI phenology from daily rainfall: a simple four parameter coupled-reservoir model.

**International Journal of Remote Sensing**, Abingdon, v. 36, n. 22, p. 5637-5663, 2015.

HILL, Michael J. Vegetation Index Suites as Indicators of Vegetation State in Grassland and Savanna: An Analysis with Simulated SENTINEL 2 Data for a North American Transect.

**Remote Sensing of Environment**, Amsterdam, v. 137, p. 94-111, 2013.

HOTT, Marcos Cicarini et al. Vegetative growth of grasslands based on hyper-temporal

NDVI data from the Modis sensor. **Pesquisa Agropecuária Brasileira**, Brasília, v. 51, n. 7, p. 858-868, 2016.

HUETE, Alfredo et al. Overview of the radiometric and biophysical performance of the

MODIS vegetation indices. **Remote Sensing of Environment**, Amsterdam, v. 83, n. 1-2, p. 195-213, 2002.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). A soil-adjusted vegetation

index (SAVI). **Remote sensing of environment**, Amsterdam, v. 25, p. 295-309, 1988.

HUETE, Alfredo; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for

MODIS-EOS. **Remote Sensing of environment**, Amsterdam, v. 49, n. 3, p. 224-234, 1994.

IBGE, R. **Manual técnico da vegetação brasileira**. 2ª ed. Rio de Janeiro: IBGE, 275p, 2012.

IRONS, James R.; DWYER, John L.; BARSÍ, Julia A. The next Landsat satellite: The

Landsat data continuity mission. **Remote Sensing of Environment**, Amsterdam, v. 122, p. 11-21, 2012.

JOBÁGY, Esteban G.; SALA, Osvaldo E. Controls of grass and shrub aboveground

production in the Patagonian steppe. **Ecological Applications**, Washington, v. 10, n. 2, p. 541-549, 2000.

JONES, Matthew O. et al. Innovation in rangeland monitoring: annual, 30 m, plant functional

type percent cover maps for U.S. rangelands, 1984-2017. **Ecosphere**, Washington, v. 9, n. 9, p. e02430, 2018.

KAITHO, R. J. et al. Livestock early warning information resource in the Horn of Africa:

forage and livestock marketing information analysis and forecasts. **Outlook on Agriculture**, Thousand Oaks, v. 36, n. 4, p. 267-272, 2007.

KARNIELI, A. et al. Do vegetation indices provide a reliable indication of vegetation

degradation? A case study in the Mongolian pastures. **International Journal of Remote Sensing**, Abingdon, v. 34, n. 17, p. 6243-6262, 2013.

LANDIS, J. Richard; KOCH, Gary G. The measurement of observer agreement for

categorical data. **Biometrics**, Washington, v. 33, n. 1, p. 159-174, 1977.

LAOSUWAN, Teerawong; UTTARUK, Pornchai. Estimating tree biomass via remote

sensing, MSAVI 2, and fractional cover model. **IETE Technical Review**, New Delhi, v. 31, n. 5, p. 362-368, 2014.

- LARA, Márcio André Stefanelli; RAKOCEVIC, Miroslava. Uso de modelos matemáticos no estudo de pastagens. **Forragicultura: Ciência, Tecnologia e Gestão dos Recursos Forrageiros**. Jaboticabal: Funep, p. 333-346, 2014.
- LEE, Soo-Jin et al. On the relationships between satellite-based drought index and gross primary production in the North Korean croplands, 2000–2012. **Remote Sensing Letters**, v. 7, n. 8, p. 790-799, 2016.
- LU, Dengsheng et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, Londres, v. 9, n. 1, p. 63-105, 2016.
- MAGLIANO, Patricio N. et al. Precipitation Event Distribution in Central Argentina: Spatial and Temporal Patterns. **Ecohydrology**, v. 8, n. 1, p. 94-104, 2015.
- MAIA, Stoécio Malta Ferreira et al. Organic carbon pools in a Luvisol under agroforestry and conventional farming systems in the semi-arid region of Ceará, Brazil. **Agroforestry systems**, Amsterdam, v. 71, n. 2, p. 127-138, 2007.
- MARENGO, José A. et al. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 90, n. 2, p. 1973-1985, 2018.
- MARENGO, Jose A.; TORRES, Roger Rodrigues; ALVES, Lincoln Muniz. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, Berlin, v. 129, n. 3-4, p. 1189-1200, 2017.
- MARIN, Fábio R.; JONES, James W. Process-based simple model for simulating sugarcane growth and production. **Scientia Agrícola**, Piracicaba, v. 71, n. 1, p. 1–16, 2014.
- MATERE, Joseph et al. Predictive Livestock Early Warning System (PLEWS): Monitoring forage condition and implications for animal production in Kenya. **Weather and Climate Extremes**, v. 27, p. 100209, 2020.
- MENDES, S. et al. Remote sensing and GIS combination to evaluate the ecosystems' conditions in "Serras do Porto". In: **Remote Sensing for Agriculture, Ecosystems, and Hydrology XX**. Bellingham, International Society for Optics and Photonics, 2018. p. 107832E.
- MIDEKISA, Alemayehu et al. Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. **PLoS ONE**, San Francisco, v. 12, n. 9, p. e0184926, 2017.
- MOREIRA, Francisco TA et al. Floristic Characterization and Phytosociology of a Vegetation in a Caatinga Area in Brazil. **Journal of Experimental Agriculture International**, West Bengal, v. 30, n. 5, p. 1-10, 2019.
- MORITZ, Mark et al. Open access, open systems: pastoral management of common-pool resources in the Chad Basin. **Human Ecology**, Berlin, v. 41, n. 3, p. 351-365, 2013.

MUIR, James Pierre et al. Value of endemic legumes for livestock production on Caatinga rangelands. **Revista Brasileira de Ciências Agrárias**, Recife, v. 14, n. 2, 2019.

MYNENI, Ranga B. et al. The interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, Pasadena, v. 33, n. 2, p. 481-486, 1995.

NOGUEIRA, Narjara Walessa et al. Alternativas alimentares para ovinos e caprinos no semiárido brasileiro. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, Pombal, v. 5, n. 2, p. 5-12, 2010.

OTAVIANO, Emanoella Karol Saraiva. **Composição botânica da dieta e índice de seletividade de pequenos ruminantes em pastejo no semiárido brasileiro**. Dissertação de Mestrado, Departamento de Zootecnia, Fortaleza, Universidade Federal do Ceará. pag. 46, 2020.

OTGONBAYAR, Munkhdulam et al. Mapping pasture biomass in Mongolia using Partial Least Squares, Random Forest regression and Landsat 8 imagery. **International Journal of Remote Sensing**, Abingdon, v. 40, n. 8, p. 3204-3226, 2019.

PAREDES-TREJO, Franklin J.; BARBOSA, H. A.; KUMAR, TV Lakshmi. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of arid environments**, Londres, v. 139, p. 26-40, 2017.

PEARSON, Robert Lawrence; MILLER, Lee Durward. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie. v. rse, p. 1355, 1972.

PINHEIRO, Felipe M.; NAIR, PK Ramachandran. Silvopasture in the Caatinga biome of Brazil: A review of its ecology, management, and development opportunities. **Forest Systems**, Madrid, v. 27, n. 1, p. 1-16, 2019.

PROVENZA, F. D.; GREGORINI, Pablo; CARVALHO, Paulo Cesar Faccio. Synthesis: foraging decisions link plants, herbivores and human beings. **Animal Production Science**, Sidney, v. 55, n. 3, p. 411-425, 2015.

QI, Jianguo et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, Amsterdam, v. 48, n. 2, p. 119-126, 1994.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. 2019. Disponível em: <https://www.Rproject.org/>. Acesso em 05 ago. 2020.

RAN, Youhua et al. Spatial representativeness and uncertainty of eddy covariance carbon flux measurements for upscaling net ecosystem productivity to the grid scale. **Agricultural and Forest Meteorology**, Amsterdam, v. 230-231, n. 15, p. 114-127, 2016.

RAO, Idupulapati M. et al. LivestockPlus—The sustainable intensification of forage-based agricultural systems to improve livelihoods and ecosystem services in the tropics. **Tropical Grasslands-Forrajões Tropicais**, Cali, v. 3, n. 2, p. 59-82, 2015.

REIS, Ricardo Andrade et al. Suplementação da dieta de bovinos de corte como estratégia do

manejo das pastagens. **Revista Brasileira de Zootecnia**, Viçosa, v. 38, n. spe, p. 147-159, 2009.

REN, Hongrui; ZHOU, Guangsheng; ZHANG, Feng. Using negative soil adjustment factor in soil-adjusted vegetation index (SAVI) for aboveground living biomass estimation in arid grasslands. **Remote Sensing of Environment**, Amsterdam, v. 209, p. 439-445, 2018.

RENZA, Diego et al. Drought estimation maps by means of multirate Landsat fused images. In: **Proceedings of the 30th EARSeL Symposium**. 2010.

REYNOLDS, James F. et al. Global desertification: building a science for dryland development. **Science**, Washington, v. 316, n. 5826, p. 847-851, 2007.

RHODES, Edward C. et al. A comparison of rangeland monitoring techniques for modeling herbaceous fuels and forage in central Arizona, USA. **Fire Ecology**, v. 10, n. 2, p. 76-91, 2014.

RIBEIRO, Eláine MS et al. Chronic anthropogenic disturbance drives the biological impoverishment of the Brazilian Caatinga vegetation. **Journal of Applied Ecology**, Londres, v. 52, n. 3, p. 611-620, 2015.

ROBINSON, Timothy P. et al. **Global livestock production systems**. Rome, Food and Agriculture Organization of the United Nations (FAO) and International Livestock Research Institute (ILRI), 152 pp, 2011.

ROBINSON, Timothy P. et al. Mapping the Global Distribution of Livestock. **PLoS ONE**, San Francisco, v. 9, n. 5, p. 232-240, 2014.

ROY, David P. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, Amsterdam, v. 145, p. 154-172, 2014.

RUFINO, Iana Alexandra Alves; SILVA, Simone Tavares da. Análise das relações entre dinâmica populacional, clima e vetores de mudança no semiárido brasileiro: Uma abordagem metodológica. **Boletim de Ciências Geodésicas**, Curitiba, v. 23, n. 1, p. 166-181, 2017.

SALIMON, Cleber; ANDERSON, Liana. How strong is the relationship between rainfall variability and Caatinga productivity? A case study under a changing climate. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 90, n. 2, p. 2121-2127, 2018.

SAMPAIO, Everardo VSB; MARIA DO SOCORRO, B. Araújo; SAMPAIO, Yony SB. Propensão à desertificação no semiárido brasileiro. **Revista de Geografia**, Recife, v. 22, n. 2, p. 59-76, 2008.

SANDS, P. J.; LANDSBERG, J. J. Parameterisation of 3-PG for plantation grown Eucalyptus globulus. **Forest Ecology and Management**, Amsterdam, v. 163, n. 1-3, p. 273-292, 2002.

SANTOS, Mércia Virginia Ferreira dos et al. Potential of Caatinga forage plants in ruminant feeding. **Revista Brasileira de Zootecnia**, Viçosa, v. 39, p. 204-215, 2010.

SANTOS, Patricia Menezes et al. Mudanças climáticas globais e a pecuária: cenários futuros

para o Semiárido brasileiro. **Revista Brasileira de Geografia Física**, Recife, v. 06, p. 1176-1196, 2011.

SAYRE, Nathan F. et al. Earth stewardship of rangelands: coping with ecological, economic, and political marginality. **Frontiers in Ecology and the Environment**, Washington, v. 11, n. 7, p. 348-354, 2013.

SHA, Zongyao et al. Comparison of leaf area index inversion for grassland vegetation through remotely sensed spectra by unmanned aerial vehicle and field-based spectroradiometer. **Journal of Plant Ecology**, Oxford, v. 12, n. 3, p. 395-408, 2019.

SHAHABFAR, A.; EITZINGER, J. Agricultural drought monitoring in semi-arid and arid areas using MODIS data. **The Journal of Agricultural Science**, Cambridge, v. 149, n. 4, p. 403-414, 2011.

SHEFFIELD, Justin; WOOD, Eric F. Global trends and variability in soil moisture and drought characteristics, 1950–2000, from observation-driven simulations of the terrestrial hydrologic cycle. **Journal of Climate**, Massachusetts, v. 21, n. 3, p. 432-458, 2008.

SIBANDA, Mbulisi et al. Estimating biomass of native grass grown under complex management treatments using worldview-3 spectral derivatives. **Remote Sensing**, Basel, v. 9, n. 1, p. 55, 2017.

SILVA, Aderbal Marcos de Azevedo et al. Manejo da Caatinga para produção de caprinos e ovinos. **Revista Brasileira de Saúde e Produção Animal**, Salvador, v. 14, n. 1, p. 77-90, 2013.

SMITH, Jimmy et al. Beyond milk, meat, and eggs: Role of live-stock in food and nutrition security. **Animal Frontiers**, Champaign, v. 3, p. 6–13, 2013.

SOUZA, Bartolomeu Israel; MENEZES, Rafael; CAMARA ARTIGAS, Rafael. Desertification effects on the species composition of the Caatinga biome, Paraíba/Brazil. **Investigaciones Geográficas**, San Vicente del Raspeig, v. 88, p. 45-59, 2015.

STUTH, Jerry Stuth. et al. **Phygrow Users Guide and Technical Documentation**. Texas A&M University, College Station, Texas, USA, 2003.

STUTH, JERRY W. et al. Livestock early warning system for Africa rangelands. **Monitoring and predicting agricultural drought: a global study**. New York, NY, USA: Oxford, p. 283-296, 2005.

TAVAZOHI, Elena; AHMADI, M. Assessment Of Drought In The Zayandehroud Basin During 2000–2015 Using Nddi And Spi Indices. **Fresenius Environmental Bulletin**, v. 27, n. 4, p. 2332-2340, 2018.

TEDESCHI, Luis Orlindo. Assessment of the adequacy of mathematical models. **Agricultural Systems**, Amsterdam, v. 89, n. 2–3. p. 225-247, 2006.

TEIXEIRA, David Bruno de Sousa. Correlation between precipitation and vegetation indexes under preserved Caatinga condition. **Journal of Hyperspectral Remote Sensing**, Recife, v.

7, n. 1, p. 21-30, 2016.

THORNTON, Philip K. et al. Vulnerability, Climate Change and Livestock– Res. Opportunities and Challenges for Poverty Alleviation, ICRISAT Int. **Livestock Res. Inst.**, v. 4, n. 1, pp 21–32,. 2007.

TIETJEN, Britta; JELTSCH, Florian. Semi-Arid Grazing Systems and Climate Change: A Survey of Present Modelling Potential and Future Needs. **Journal of Applied Ecology**, Londres, v. 44, n.2, pp. 425 – 434, 2007.

VERMOTE, E. F.; KOTCHENOVA, S. Y.; RAY, J. P. MODIS Land surface reflectance science computing facility. **MODIS Surface Reflectance User’s Guide**; version, v. 1, 2011.

VERRELST, Jochem et al. Effects of woody elements on simulated canopy reflectance: Implications for forest chlorophyll content retrieval. **Remote Sensing of Environment**, Amsterdam, v. 114, n. 3, p. 647-656, 2010.

VERRELST, Jochem et al. Quantifying vegetation biophysical variables from imaging spectroscopy data: a review on retrieval methods. **Surveys in Geophysics**, New York, v. 40, n. 3, p. 589-629, 2019.

VERSTRAETE, Michel M.; SCHOLES, Robert J.; SMITH, Mark Stafford. Climate and desertification: looking at an old problem through new lenses. **Frontiers in Ecology and the Environment**, Washington, v. 7, n. 8, p. 421-428, 2009.

VIEIRA, Rita Marcia da Silva Pinto et al. Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 28, n. 2, p. 129-138, 2013.

VRIELING, Anton; DE BEURS, Kirsten M.; BROWN, Molly E. Variability of African farming systems from phenological analysis of NDVI time series. **Climatic change**, Berlin, v. 109, n. 3-4, p. 455-477, 2011.

WARREN, Georgina; METTERNICHT, Graciela. Agricultural applications of high-resolution digital multispectral imagery. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 71, n. 5, p. 595-602, 2005.

WEI, Taiyun et al. Package ‘corrplot’. **Statistician**, v. 56, n. 316, p. e24, 2017.

WILLMOTT, Cort J. On the validation of models. **Physical geography**, v. 2, n. 2, p. 184-194, 1981.

XIONG, Jun et al. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 126, p. 225-244, 2017.

YUAN, Huanhuan et al. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of RF, ANN, and SVM regression models. **Remote Sensing**, Basel, v. 9, n. 4, p. 309, 2017.

ZANDLER, Harald; BRENNING, A.; SAMIMI, C. Quantifying dwarf shrub biomass in an arid environment: Comparing empirical methods in a high dimensional setting. **Remote Sensing of Environment**, Amsterdam, v. 158, p. 140-155, 2015.

ZHANG, Binghua et al. Application of synthetic NDVI time series blended from Landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, Basel, v. 8, n. 1, p. 10, 2016.

ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, New York, v. 13, n. 6, p. 693-712, 2012.

ZHANG, Xiaoyang et al. Monitoring vegetation phenology using MODIS. **Remote sensing of environment**, Amsterdam, v. 84, n. 3, p. 471-475, 2003.

ZHANG, Zhi-Ying et al. Remote sensing and spatial statistical analysis to predict the distribution of *Oncomelania hupensis* in the marshlands of China. **Acta Tropica**, Amsterdam, v. 96, n. 2-3, p. 205-212, 2005.

ZHAO, Peisheng; FOERSTER, Theodor; YUE, Peng. The geoprocessing web. **Computers & Geosciences**, v. 47, p. 3-12, 2012.

ZILVERBERG, Cody J. et al. Process-based simulation of prairie growth. **Ecological Modelling**, Amsterdam, v. 351, n. 10, p. 24-35, 2017.

ZOCCAL, Rosangela; ASSIS, Airdem Gonçalves de; EVANGELISTA, Silvio Roberto de Medeiros. Distribuição geográfica da pecuária leiteira no Brasil. **Revista de Política Agrícola**, Brasília, v. 15, n. 4, p. 47-58, 2006.