

**UNIVERSIDADE FEDERAL DE ALAGOAS  
CAMPUS DE ENGENHARIAS E CIÊNCIAS AGRÁRIAS  
BACHARELADO EM ENGENHARIA DE AGRIMENSURA**

**DIEGO MEDEIROS TENORIO TAVARES**

**ANÁLISE AMBIENTAL DO PARQUE NACIONAL DE SETE CIDADES-PI  
UTILIZANDO GOOGLE EARTH ENGINE**

**RIO LARGO – AL**

**2020**

**DIEGO MEDEIROS TENORIO TAVARES**

**ANÁLISE AMBIENTAL DO PARQUE NACIONAL DE SETE CIDADES-PI  
UTILIZANDO GOOGLE EARTH ENGINE**

Monografia apresentada ao curso de Bacharelado em Engenharia de Agrimensura do Campus de Engenharias e de Ciências Agrárias da Universidade Federal de Alagoas, como requisito para a obtenção do título de Engenheiro Agrimensor.

Orientador(a): MSc. Michelle Adelino Cerqueira

**RIO LARGO – AL**

**2020**

Catálogo na Fonte  
Universidade Federal de Alagoas  
Biblioteca Campus de Engenharias e Ciências Agrárias  
Bibliotecário: Erisson Rodrigues de Santana

T231a Tavares, Diego Medeiros Tenorio

Análise ambiental do parque nacional de Sete Cidades-PI utilizando google earth engine. / Diego Medeiros Tenorio Tavares. – 2020.

87 f.; il; 33 cm

Trabalho de Conclusão de Curso - (Bacharelado em Engenharia de Agrimensura) – Campus de Engenharias e Ciências Agrárias, Universidade Federal de Alagoas. Rio Largo, 2020.

Orientador(a): Msc. Michelle Adelino Cerqueira.

1. Índices espectrais. 2. Sensores Orbitais. 3. Unidades de Conservação. 4. Sensoriamento remoto. I. Título.

CDU: 528.8

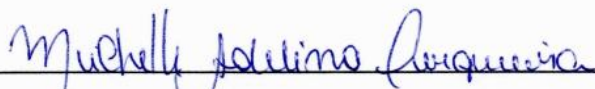
**Folha de Aprovação**

**DIEGO MEDEIROS TENORIO TAVARES**

**ANÁLISE AMBIENTAL DO PARQUE NACIONAL DE SETE CIDADES-PI  
UTILIZANDO GOOGLE EARTH ENGINE**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia de Agrimensura do Centro de Engenharias e Ciências Agrárias como requisito parcial à obtenção do grau de Bacharel em Engenharia.

Aprovado em 03 de março de 2020.



---

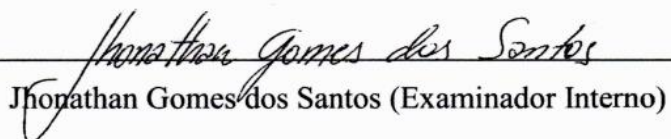
Michelle Adelino Cerqueira (Orientadora)

**Banca Examinadora:**



---

Ramon Salgueiro Cruz (Examinador Interno)



---

Jhonathan Gomes dos Santos (Examinador Interno)

## AGRADECIMENTOS

Início meus agradecimentos expressando minha gratidão a todos os envolvidos na construção da pessoa que me tornei, especialmente, à minha avó, **Carmosina Medeiros Tenório**, e a minha mãe, **Mércia Fátima**, que apesar das dificuldades enfrentadas para criar seus filhos após o falecimento precoce de meu pai, foi exitosa nessa missão com a ajuda de minha avó.

Sigo agradecendo aos docentes que estiveram na minha trajetória do ensino básico, pois eles ajudaram a edificar meu conhecimento e caráter com dedicação e atenção. Agradeço aos meus professores e professoras do ensino superior, inicialmente aos que estiveram comigo no IFAL, destacando a importância de **Walter Vianna Jr.** que com suas palavras me conduziu a tomar um caminho diferente, levando-me à UFAL.

Nessa instituição reitero meus agradecimentos a **Almair Camargos**, **Ravi Almeida** e **Arthur Tavares**, que mais do que mentores, se tornaram amigos; **Jhonathan Gomes** e **Juciela Santos**, pelo incentivo a pensar por diferentes perspectivas e superar as ocorrentes dificuldades; **Michelle Adelino** por enxergar em mim um potencial além da realidade; **Rafaella Faciola**, a quem embora eu a tenha decepcionado, influenciou fortemente decisões que tomei; e, muito especialmente, **Regla Toujaguez Massahud**, pois como uma segunda mãe sempre me acolheu e aconselhou, além de me orientar durante a iniciação científica.

Gratidão aos meus amigos **Felipe França** pela fundamental ajuda no processo de intercâmbio; **Lucas Lopes**, **Carlos Vilela**, **Thales Henrique**, **Guilherme Frick**, **Nicollas Assunção** e **Andressa Moreira**, companheiros de intercâmbio; **Fernando Barros**, **Edigar Cavalcante**, **Diva Cordeiro**, **Jonathan Eloy**, **Flávia Santos**, **Patrícia Araújo** e **Emanuel Costa**, pelo incentivo a seguir a profissão de engenheiro e apoio nas piores horas.

Grato às empresas **Arqmensura Topografia e Projetos**, **Fierro & Company** e **Usina Coruripe**, pela oportunidade de aprendizado e crescimento pessoal.

Por último, mas não menos importante, agradeço especialmente à minha namorada **Rayssa Melo** que aguentou minha teimosia, esporádica ausência e aperreio durante todo o longo tempo de execução deste trabalho.

**Obrigado!**

## RESUMO

Os ambientes de grande diversidade ecológica e beleza cênica que são consideradas as unidades de conservação têm como seu principal objetivo a preservação de tais atributos. Esses locais necessitam de mecanismos que favoreçam sua manutenção, dando aos gestores insumos sobre a dinâmica natural para que possam tomar decisões mais assertivas em relação às ações protetivas, visto que em poucas unidades são encontrados meios para subsidiar tais ações. Assim, o objetivo desse trabalho é apresentar uma metodologia de baixo custo para a análise das mudanças ambientais, de forma sazonal, visando prevenir a possibilidade de degradação do Parque Nacional de Sete Cidades, unidade de conservação localizada na zona rural dos municípios de Brasileira-PI e Piracuruca-PI, que foi escolhido para o estudo após uma busca por regiões de áreas de preservação nos estados do Nordeste. O presente trabalho constitui-se com base no sensoriamento remoto, método que utiliza também sensores orbitais com o intuito de capturar dados sobre a superfície terrestre e através deles quantificar níveis de precipitação, perceber estágios de desenvolvimento da vegetação, além da ocorrência de estresse hídrico. O *corpus* da pesquisa teve base nos dados obtidos utilizando o sensoriamento remoto que possibilitou o cálculo de índices espectrais. Tais índices foram produzidos através da plataforma de processamento em nuvem *Google Earth Engine* que gerou informações sobre as condições da vegetação, essas informações foram analisadas e transformadas em mapas no *software* QGIS 3.4 um sistema de informações geográficas. Após análise e tratamento dos dados constatamos que a vegetação sofre grande influência da precipitação na maior parte dos índices, podendo afetar ou não a exposição do solo a depender da escassez das chuvas, no entanto, a vegetação apresenta-se resiliente, conseguindo recuperar-se nos períodos chuvosos na área do Parque.

**Palavras-Chave:** Índices espectrais; Sensores Orbitais; Unidades de Conservação; Sensoriamento remoto.

## ABSTRACT

The conservation unities are environments where exist very significant ecological diversity and beautiful landscapes. The major reason for their creation is the preservation of these attributes. They demand the conception of mechanisms to support their maintenance and provide managers with data about environmental dynamics to enable them make decisions related to protective actions rightfully, once there are means to contribute for this accomplishment only in a few of those unities. So on, this research has as a goal to provide a low cost methodology to analyze seasonal environmental changes, looking for prevent possible degradation processes on the Seven Cities National Park, a conservation unit located in the Rural Zone of the towns Brasileira-PI and Piracuruca-PI, which was chosen for analysis after a survey has done by regions of conservation areas in the states of the Northeast. The current study is based on remote sense methods using in an advantageous way orbit sensors to collect data about Earth's surface at the region of interest and by them quantify precipitation levels, identify development stages of natural vegetation and the occurrence of plant hydrological stress. The *corpus* of this research is based on remote sensed data used to compute spectral indexes calculated through an online cloud processing program as known as Google Earth Engine. It produced information about vegetation condition that passed over analyses and it was checked to be mapped using a geographical information system (GIS) called QGIS 3.4. Then as a result it is possible to observe a resiliente behavior in the vegetation while it is influenced by the precipitation levels that can promote transformation from vegetated areas into bare land or bare rock if a low level of precipitation has occurred, and recover after rainfall periods over the Park area.

**Key-words:** Spectral indexes; Orbital sensors; Conservation unities; Remote sense.

## LISTA DE FIGURAS

<b>Figura 1.</b> Espectro eletromagnético .....	17
<b>Figura 2.</b> Esquema do satélite <i>ERTS (Landsat 1)</i> .....	22
<b>Figura 3.</b> Arte conceitual do satélite <i>Landsat 2</i> em órbita .....	23
<b>Figura 4.</b> Satélite <i>Landsat 3</i> .....	23
<b>Figura 5.</b> Modelo do satélite <i>Landsat 4</i> .....	23
<b>Figura 6.</b> Desenho do satélite <i>Landsat 5</i> .....	25
<b>Figura 7.</b> Esboço do <i>Landsat 6</i> em órbita.....	27
<b>Figura 8.</b> Satélite <i>Landsat 7</i> .....	27
<b>Figura 9.</b> Satélite <i>Landsat 8</i> .....	28
<b>Figura 10.</b> Exemplo de correção atmosférica realizada pelo <i>LaSRC</i> : à esquerda imagem em Reflectância do Topo da Atmosfera ( <i>TOA</i> ); à direita imagem em Reflectância de Superfície ( <i>SR</i> ) .....	32
<b>Figura 11.</b> <i>Interface</i> do <i>Code Editor</i> do <i>Google Earth Engine</i> .....	37
<b>Figura 12.</b> Mapa de localização.....	40
<b>Figura 13.</b> Mapeamento das classes de vegetação do <i>PNSC</i> .....	40
<b>Figura 14.</b> Fluxograma .....	42
<b>Figura 15.</b> Precipitação mensal no período de estudo.....	49
<b>Figura 16.</b> Dispersão dos dados pluviométricos diários no ciclo sazonal 2013/2014 .....	50
<b>Figura 17.</b> Dispersão dos dados pluviométricos diários no ciclo sazonal 2014/2015 .....	51
<b>Figura 18.</b> Somatório dos dados pluviométricos diários agrupados por estação do ano .....	51
<b>Figura 19.</b> Média dos <i>NDVI</i> em relação à precipitação acumulada.....	50
<b>Figura 20.</b> Média dos <i>EVI 2</i> em relação à precipitação acumulada .....	50
<b>Figura 21.</b> Média dos <i>EVI 2</i> em relação à precipitação acumulada .....	54
<b>Figura 22.</b> Média dos <i>LAI</i> em relação à precipitação acumulada .....	54
<b>Figura 23.</b> Média dos <i>NDWI Gao</i> em relação à precipitação acumulada .....	55
<b>Figura 24.</b> Cobertura percentual das classes dos <i>NDVI</i> e precipitação acumulada em relação às estações .....	56
<b>Figura 25.</b> Parque Nacional de Sete Cidades - <i>NDVI</i> do primeiro ciclo estacionário 2013/2014 .....	58
<b>Figura 26.</b> Parque Nacional de Sete Cidades - <i>NDVI</i> do segundo ciclo estacionário 2014/2015 .....	59
<b>Figura 27.</b> Cobertura percentual do <i>EVI 2</i> e precipitação acumulada em relação às estações .....	61
<b>Figura 28.</b> Parque Nacional de Sete Cidades – <i>EVI 2</i> do primeiro ciclo estacionário 2013/2014.....	59
<b>Figura 29.</b> Parque Nacional de Sete Cidades – <i>EVI 2</i> do segundo ciclo estacionário 2014/2015 .....	60
<b>Figura 30.</b> Cobertura percentual do <i>MSAVI 2</i> e precipitação acumulada em relação às estações .....	65
<b>Figura 31.</b> Parque Nacional de Sete Cidades – <i>MSAVI 2</i> do primeiro ciclo estacionário 2013/2014..	66
<b>Figura 32.</b> Parque Nacional de Sete Cidades – <i>MSAVI 2</i> do segundo ciclo estacionário 2014/2015 ..	67
<b>Figura 33.</b> Cobertura percentual do <i>NDWI Gao</i> e precipitação acumulada em relação às estações.....	69
<b>Figura 34.</b> Parque Nacional de Sete Cidades – <i>NDWI Gao</i> do primeiro ciclo estacionário 2013/2014 .....	70
<b>Figura 35.</b> Parque Nacional de Sete Cidades – <i>NDWI Gao</i> do segundo ciclo estacionário 2014/2015	71
<b>Figura 36.</b> Cobertura percentual do <i>LAI</i> e precipitação acumulada em relação às estações .....	70
<b>Figura 37.</b> Parque Nacional de Sete Cidades – <i>LAI</i> do primeiro ciclo estacionário 2013/2014.....	74
<b>Figura 38.</b> Parque Nacional de Sete Cidades – <i>LAI</i> do segundo ciclo estacionário 2014/2015 .....	75



## SUMÁRIO

1	INTRODUÇÃO .....	11
2	OBJETIVOS.....	13
2.1	Objetivo geral.....	13
2.2	Objetivos específicos .....	13
3	FUNDAMENTAÇÃO TEÓRICA .....	14
3.1	Sensoriamento Remoto .....	14
3.1.1	Conceituação do Sensoriamento Remoto .....	14
3.1.2	Processo evolutivo do Sensoriamento Remoto .....	14
3.1.3	Sistemas de sensoriamento remoto.....	17
3.1.4	Radiação Eletromagnética .....	18
3.2	Programa <i>Landsat</i> .....	19
3.2.1	Iniciativa .....	19
3.2.2	<i>Landsat</i> 1, 2 e 3.....	20
3.2.3	<i>Landsat</i> 4.....	23
3.2.4	<i>Landsat</i> 5.....	24
3.2.5	<i>Landsat</i> 6.....	26
3.2.6	<i>Landsat</i> 7.....	27
3.2.7	<i>Landsat</i> 8.....	28
3.3	Correção geométrica .....	29
3.4	Correção radiométrica.....	30
3.5	Correção atmosférica .....	31
3.6	<i>Landsat</i> 8 Surface Reflectance Code (LaSRC).....	32
3.7	Índices de Vegetação .....	32
3.7.1	Normalized Difference Vegetation Index (NDVI) .....	33
3.7.2	Enhanced Vegetation Index 2 (EVI 2) .....	34
3.7.3	Modified Soil-Adjusted Vegetation Index 2 (MSAVI 2) .....	34
3.7.4	Normalized Difference Water Index Gao (NDWI Gao) .....	35
3.7.5	Leaf Area Index (LAI).....	35
3.8	Climate Hazards Group InfraRed Precipitation with Stations (CHIRPS) .....	36
3.9	Plataforma de processamento em nuvem <i>Google Earth Engine</i> .....	37
4	MATERIAL E MÉTODOS .....	39

4.1	Localização e caracterização da área de estudo.....	39
4.2	Material e <i>softwares</i> utilizados .....	42
4.3	Metodologia aplicada.....	42
4.3.1	Entrada dos dados.....	45
4.3.2	Geração do mosaico temporal .....	46
4.3.3	Remoção de nuvens e sombras de nuvens.....	47
4.3.4	Geração do mosaico ( <i>composite</i> ) de medianas.....	47
4.3.5	Recorte das imagens .....	47
4.3.6	Cálculo das precipitações .....	48
4.3.7	Cálculo de índices espectrais .....	48
4.3.8	Exportação dos resultados .....	48
5	RESULTADOS E DISCUSSÃO .....	49
5.1	Análise dos dados pluviométricos .....	49
5.2	Análise dos índices biofísicos em relação à pluviometria .....	52
6	CONCLUSÃO .....	76
	ANEXO A .....	78
	REFERÊNCIAS BIBLIOGRÁFICAS .....	85

## 1 INTRODUÇÃO

Em virtude de garantir a proteção e preservação de sistemas naturais ou culturais únicos ou extraordinários é atribuído àquele no cargo de Presidente da República a responsabilidade sobre a criação dos Parques Nacionais brasileiros através de Decreto Federal. Sendo esses incorporados ao patrimônio público, e assim submetidos à inalienabilidade e indisponibilidade jurídica em seus limites uma vez adquiridos através de doações, compras, desapropriações ou qualquer outra forma lícita de aquisição. Esses locais oferecem aos brasileiros a oportunidade de desenvolvimento à educação ambiental, recreação e pesquisa científica (IBDF, 1979).

Logo, é dever do Poder Público promover a manutenção dos parques, evitando que neles ocorra degradação das riquezas naturais, portanto, para que tais desígnios sejam cumpridos é demandado o desenvolvimento de um planejamento específico para cada parque, fornecendo características e diretrizes básicas, estruturadas em um plano de manejo, que é o documento técnico mediante o qual, com fundamento nos objetivos gerais de uma unidade de conservação, se estabelece o seu zoneamento e as normas que devem presidir o uso da área e o manejo dos recursos naturais. O Sistema Nacional de Unidades de Conservação (SNUC) define unidade de conservação (UC), como o espaço territorial e seus recursos ambientais, incluindo as águas jurisdicionais, com características naturais relevantes, legalmente instituídos pelo Poder Público, com objetivos de conservação e limites definidos, sob regime especial de administração, ao qual se aplicam garantias de proteção (MMA, 2020).

Tal instrumento deve apresentar zoneamentos e estratégias com cronogramas e flexibilidade suficientes para adequar-se à atualização de situação, descobertas científicas e novas metodologias que garantam maior eficiência às ações de proteção nas unidades de conservação. No entanto, parte significativa do patrimônio público ambiental encontra-se em déficit quanto aos planos de manejo, a exemplo do Parque Nacional de Sete Cidades, no qual o plano é datado em 1979 (IBDF, 1979).

Há algumas décadas a atividade de caracterização dos recursos da superfície terrestre era onerosa e excessivamente laboriosa, não sendo possível acompanhar muitas vezes o tempo de mudanças de algumas variáveis. Contudo, com a disseminação das geotecnologias, em especial a distribuição gratuita de produtos de sensoriamento remoto de qualidade, tornou-se

mais eficiente o levantamento de informações e reconhecimento de padrões em áreas grandes ou reclusas.

Com esses insumos inúmeros cientistas desenvolveram estudos e métodos sobre classificação de solos e vegetação, identificação de estágios da fenologia vegetal, monitoramento de incêndios e desflorestamento entre outros temas de interesse, sempre no intuito de proporcionar meios para que o meio ambiente seja protegido das atividades exploratórias da humanidade e adversidades naturais.

Este trabalho tem como objetivo a realização de análise da vegetação da área pertencente ao perímetro do Parque Nacional de Sete Cidades, observando seu comportamento em relação à sazonalidade. Para isso foram utilizadas imagens do satélite *Landsat 8 OLI* - Resolução Espacial (MS) 30m, ditas de média resolução, processadas na plataforma online *Google Earth Engine*, onde foram implementados índices biofísicos através de programação em linguagem *JavaScript* para então avaliar os padrões apresentados nos índices e identificar as alterações no ambiente vegetativo em relação à variação dos níveis de pluviosidade, visando apresentar uma metodologia capaz de auxiliar em possíveis intervenções em áreas ambientalmente sensíveis para mitigação das atividades antrópicas, apresentando-se como uma alternativa de baixo custo.

Para concluir apresentamos como esta monografia está dividida em seus capítulos. O primeiro capítulo, “Fundamentação Teórica”, aborda os aspectos fundamentais e teóricos que servirão como base para as análises, no segundo, “Materiais e Métodos” consta a descrição dos meios e dos dispositivos utilizados para desenvolver a pesquisa. No capítulo seguinte temos a seção dos “Resultados e Discussões” que analisa os resultados embasados na literatura utilizada e por fim, a “Conclusão”, que apresenta as observações obtidas a partir da realização deste trabalho, evidenciando também propostas que possam ser adotadas para melhoria nos resultados das informações geradas.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Analisar a dinâmica da vegetação do Parque Nacional de Sete Cidades entre as estações climáticas, utilizando índices espectrais processados na plataforma *Google Earth Engine*.

### **2.2 Objetivos específicos**

- Avaliar o comportamento dos índices biofísicos por dados orbitais;
- Implementar índices espectrais através da plataforma *Google Earth Engine*;
- Identificar a influência da pluviosidade nas alterações do ambiente vegetativo;
- Aplicar uma metodologia que sirva de subsídio para prevenção e mitigação de atividades antrópicas em unidades de conservação.

### **3 FUNDAMENTAÇÃO TEÓRICA**

#### **3.1 Sensoriamento Remoto**

##### **3.1.1 Conceituação do Sensoriamento Remoto**

O termo Sensoriamento Remoto, utilizado pela primeira vez no ano de 1960, devido à amplitude crescente que suas aplicações têm alcançado ao longo dos anos e a integração com os mais variados campos do conhecimento, não se limita mais ao mesmo significado que outrora lhe foi atribuído, podendo hoje ser aludido como uma ciência, ou estado da arte, definida como o conjunto de metodologias que simultaneamente empregam sensores e equipamentos de armazenamento, processamento e transmissão de dados transportados a bordo de diversos tipos de plataformas como aeronaves, espaçonaves e satélites com o objetivo de extrair características de fenômenos, eventos e seus desencadeamentos ocorridos na atmosfera assim como, sobre a superfície terrestre, sem estar de fato em contato com os alvos de interesse, captando destes a radiação eletromagnética (REM) naturalmente emitida e aquela refletida por eles a partir da incidência de uma fonte externa ativa ou passiva (NOVO; PONZONI, 2001; GHILANI; WOLF, 2012; SOBRINHA, 2016; SILVA FILHO, 2019).

##### **3.1.2 Processo evolutivo do Sensoriamento Remoto**

O Sensoriamento Remoto (SR) tem seu processo evolutivo relacionado com o desenvolvimento de técnicas de utilização da fotografia em diferentes ramos da ciência, como, por exemplo, a topografia. Fotografias aéreas são consideradas a primeira forma de SR, obtidas pela primeira vez por Daguerre e Niepce em 1839, tendo seu uso recomendado para levantamentos topográficos no ano seguinte. Assim, provieram-se segmentos de estudo como a fotogrametria e a fotointerpretação as quais se desenvolveram celeremente, já que o uso de fotografias tomadas durante o sobrevoo de balões para o mapeamento topográfico em várias regiões francesas foi registrado de 1858 em diante nos trabalhos executados pelo Corpo de Engenharia da França (NOVO; PONZONI, 2001).

Com o progresso das tecnologias é iniciada a era dos aviões no começo do século XX, junto a essa inovação evoluíram as câmeras fotográficas, filmes e metodologias, o que resultou em um expressivo estímulo à aplicação de aerolevantamentos no mapeamento de recursos naturais, visto que os mecanismos das aeronaves proporcionavam condições controladas para a aquisição dos dados em áreas relativamente extensas comparadas às limitações da época (NOVO; PONZONI, 2001).

Na década de 1930, aerofotografias coloridas começaram a ser produzidas. Com o advento da Segunda Guerra Mundial, a disputa tecnológica proporcionou a realização de pesquisas sobre o comportamento da radiação eletromagnética na banda espectral do infravermelho para revelar alvos camuflados, o que levou a produção de filmes sensíveis a esse tipo de radiação (NOVO; PONZONI, 2001).

Em 1956, nos Estados Unidos da América (EUA), o mapeamento das formações vegetais passou a ser realizado com aerofotografias seguindo metodologias sistematicamente elaboradas, desde o sobrevoo até sua vetorização. O Brasil, no ano de 1958 também utilizou dos produtos originados desta tecnologia para fomentar estudos sobre a Bacia Terciária do Vale do Rio Paraíba no estado de São Paulo, que por fim veio a resultar na construção do reservatório hidroelétrico do Paraibuna. Na década de 1960, os radares de microondas passaram a ser associados de forma operacional aos equipamentos os sistemas de SR, sendo o Brasil um dos pioneiros na utilização destes ao implementar o projeto Radar na Amazônia (RADAM) que promoveu 8,5 milhões de km<sup>2</sup> levantados até o final da década de 1980, utilizando a banda X do sistema *Goodeye Electronic Mapping System (GEMS)* (NOVO; PONZONI, 2001).

Com a vinda do período da Guerra Fria, na década de 1960 iniciou-se a corrida espacial surgindo com ela os sistemas orbitais. Inicialmente a aplicação desses sistemas no SR era direcionada aos estudos meteorológicos ao mesmo tempo em que câmeras fotográficas eram transportadas na série de missões *Apollo*, administradas pelo governo dos EUA, nas quais foram tomadas fotos da Terra a partir do espaço (NOVO; PONZONI, 2001).

Então em 1972 o pioneiro satélite experimental *Earth Resources Technology Satellite (ERTS)* é enviado a órbita para levantamento de recursos terrestres. Em razão da excelência alcançada na missão teve seu nome alterado para *Landsat*, se transformando com o posterior lançamento de seus sucessores no mais longo programa de sensoriamento remoto. Este programa será descrito com maiores detalhes em um tópico subsequente (NOVO; PONZONI, 2001).

Prosseguindo, foi enviado a órbita terrestre no ano de 1978 o satélite *SeaSat*, precursor entre os sistemas orbitais de radar, que teve seu período de atuação limitado a curtos três meses. O monitoramento das superfícies oceânicas através de sua coleta de dados era a destinação pela qual foi motivada sua concepção. Porém, por questões técnicas controversas à

realidade tecnológica da época a utilização de sistemas orbitais de radar foi interrompida, retornando somente na década de 1990, com o lançamento dos satélites Almaz (soviético), ERS-1 (europeu), JERS-1 (japonês) e RADARSAT (canadense) respectivamente nos anos de 1990, 1991, 1992 e 1995 (NOVO; PONZONI, 2001).

O refinamento tecnológico da interferometria por radar produziu no início do século XXI ótimos resultados na elaboração de modelos digitais de elevação (MDE), os quais são essenciais para projetos e análises vinculados às diversas áreas das geociências, pois descreve e detalha da forma mais fiel possível o terreno. Como destaque desse refinamento é observado a *Shuttle Radar Topography Mission (SRTM)*, uma missão de cooperação e realização conjunta entre a NASA (*National Aeronautics and Space Administration*) e a NIMA (*National Imaging and Mapping Agency*), dos EUA, com colaboração da DLR (*Deutsches Zentrum für Luft-und Raumfahrt*), da Alemanha, e ASI (*Agenzia Spaziale Italiana*), da Itália (PINHEIRO, 2006; BIFFI *et al.*, 2013; SANTOS *et al.*, 2009; SOUZA, 2006; SOUZA; MATRICARDI, 2013).

Com o objetivo de obter dados topográficos globais para a elaboração de MDE, o ônibus espacial *Space Shuttle Endeavour* foi lançado a partir do Centro Espacial de Kennedy, EUA, levando a bordo a *SRTM*. O *Endeavour* sobrevoou a Terra por 11 dias (de 11 a 22 de fevereiro), a uma altitude de 233 km, e inclinado a 57°. Imageou 80% da superfície terrestre, compreendendo as latitudes entre 60° Norte e 56° Sul. Para a aquisição dos 12,3 *Tbytes* de dados, foi utilizado um sistema de radar de abertura sintética interferométrico (*InSAR*), configurado para obter duas imagens ao mesmo tempo, por meio de duas antenas separadas por uma haste mecânica de 60 metros, que possuíam fases diferentes, e as elevações foram medidas através da diferença de sinais destas (PINHEIRO, 2006; BIFFI *et al.*, 2013; SANTOS *et al.*, 2009; SOUZA, 2006; SOUZA; MATRICARDI, 2013).


Dentre outros usos, além da geração de modelos de altimetria já citados, o SR vem sendo utilizado em análises do comportamento do regime de vazões de rios (AIRES; NETO; CAMPOS, 2013), monitoramento e caracterização da cobertura vegetal em bacias hidrográficas e áreas de preservação em diversas regiões (BRÉDA, 2013; BORATTO; GOMIDE, 2013; GAMEIRO *et al.*, 2016; BILAR; PIMENTEL; CERQUEIRA, 2018; MENDES; SANTOS, 2019; DIOGO; DA FONSECA; NHONGO, 2019), agricultura (DE PAULA *et al.*, 2013; PALUDO, 2019), estudos de uso e ocupação do solo, especialmente em áreas urbanas (RAMBO *et al.*, 2019), entre outras finalidades.



### 3.1.3 Sistemas de sensoriamento remoto

Os sistemas de sensoriamento remoto funcionam seguindo a mesma lógica da retina do olho do ser humano, captando a luz refletida pelos corpos (radiação eletromagnética caracterizada na faixa do espectro visível ao homem). No entanto, tais sistemas podem ser construídos para captarem não só a faixa do espectro “visível”, mas também outras regiões do espectro eletromagnético, denotadas na **figura 1** (GHILANI; WOLF, 2012).

Figura 1. Espectro eletromagnético



Fonte: Sobrinha, 2016 adaptado de Griffiths, 1999

Os sistemas são geralmente classificados como ativos: quando há emissão de radiação eletromagnética a partir de dispositivos presentes no sistema; ou passivos: quando a energia é emitida por uma fonte natural (como o Sol) e o sistema apenas captura parte da energia refletida pelos alvos (SOBRINHA, 2016).

Os sensores também se distinguem por suas resoluções, sendo a resolução espacial sua capacidade de distinguir objetos em relação a suas dimensões, dependendo da qualidade do detector, da posição e diferença de altura entre o sensor e o alvo. Define-se a resolução espectral como as regiões do espectro eletromagnético onde os sensores realizaram suas medições, sendo que quanto maior essa resolução mais bandas dedicadas a faixas mais estreitas de comprimento de onda atuam no sensor. Descrita como a eficiência do sistema na detecção e registro de pequenos sinais, a resolução radiométrica apresenta valores numéricos para a intensidade de radiância, nomeados níveis de cinza, quantificados por  $2^{\text{bits}}$  (dois elevado a potencial do número de bits, por exemplo  $2^8 = 256$  diferentes níveis de cinza). Por fim, a resolução temporal é denotada como o intervalo de tempo o qual o sensor precisa para visitar um alvo ou *footprint* (SOBRINHA, 2016).

Outra forma de classificação é quanto ao tipo de produto disponibilizado, os quais definem os sistemas como imageadores ou não-imageadores. Os primeiros capturam imagens da superfície em observação, e retornam informações sobre as variações espaciais referentes às respostas espectrais captadas. Os segundos, por sua vez, têm dados de saída numéricos ou em gráficos tendo como exemplo radiômetros e espectrorradiômetros (SOBRINHA, 2016).

Os dados dos sensores imageadores são armazenados em formato matricial (arranjos de elementos em malha ou grade), a informação de cada célula observada representa uma característica de parte do terreno, denominada *picture element (pixel)*, com dimensões de acordo com as resoluções (espacial e radiométrica) do sensor e posição geográfica do alvo. (GHILANI; WOLF, 2012; SOBRINHA, 2016).

Como vantagem, os sistemas de sensoriamento remoto por satélite oferecem menor custo se comparadas às imagens produzidas por levantamentos aerofotogramétricos tradicionais, um menor intervalo de tempo entre revisitas ao objeto-alvo, escala de cobertura que vai de local à global dependendo do satélite provedor, aplicações em diversas áreas do conhecimento e ampla distribuição em formato digital para a aplicação de técnicas de geoprocessamento. Em contrapartida, o sensoriamento remoto por satélite captura dados com maiores chances de interferência do meio (SOBRINHA, 2016).

Dentre os sistemas mais utilizados em pesquisas estão os produtos das missões *Landsat*, o mais recente e com melhor qualidade de dados é o *Landsat 8*.

### **3.1.4 Radiação Eletromagnética**

Uma vez que a matéria não se encontre a temperatura absoluta de zero *Kelvin* ela está emitindo energia, sendo considerada como provedora de radiação eletromagnética. Se esta energia é ordenada de forma contínua tomando em conta atributos como comprimento de onda ou frequência, esse arranjo pode ser chamado de espectro eletromagnético (SOBRINHA, 2016).

Em Souza (2010) é dito que em sua propagação pelo espaço a radiação eletromagnética assume o comportamento de onda, procedendo de forma diferente (comportamento de partícula) quando interagindo com a matéria. Ainda de acordo com o estudo mencionado, a propagação no espaço ocorreria através de um movimento ondulatório com os campos elétrico e magnético perpendiculares entre si. Enquanto que ao interagir com a

matéria a propagação se daria pela emissão de um fluxo de fótons (denominado Quanta), com movimento à velocidade da luz.

Diferentes composições e conjuntos de propriedades físico-químicas e/ou biológicas formam os objetos presentes na superfície terrestre, esses objetos (excluindo alguns artificiais), no entanto, emitem energia própria insuficiente para a captação por sensores. Então, a partir da emissão de radiação de uma fonte externa, incidida sobre os objetos, uma parte dessa energia é absorvida e outra parte é refletida. Cada objeto interage de forma singular com a energia, absorvendo mais ou menos diferentes comprimentos de onda do espectro, esse comportamento é que possibilita a distinção entre os diversos tipos de alvo cada qual com seu conjunto próprio de assinaturas espectrais (SOBRINHA, 2016).

### **3.2 Programa *Landsat***

O programa *Landsat* é responsável por uma coleção de 48 anos de aquisição contínua de dados espaciais iniciada no ano de 1972, atualmente gerenciado por uma parceria entre a *United States Geological Survey (USGS)* e a *National Aeronautics and Space Administration (NASA)*. Enquanto a *NASA* construiu e lançou com sucesso seis satélites do programa, a *USGS* vem operando as missões desde o final da década de 1990. Quando os dados do programa *Landsat* se tornaram abertos em 2009, visando incentivar os estudos de sensoriamento remoto ao redor do mundo, sua utilização em observação e monitoramento da superfície terrestre aumentou significativamente (YOUNG *et al.*, 2017; *USGS*, 2020).

#### **3.2.1 Iniciativa**

Enquanto eram realizados experimentos do programa *Apollo*, foram tomadas pela primeira vez, fotografias da superfície terrestre a partir do espaço, sendo esse o gatilho que inspirou o nascimento do programa *Landsat*. Em 1965, William Pecora, diretor da *United States Geological Survey (USGS)* na época, convencido pela utilidade demonstrada pelas fotografias orbitais tomadas anteriormente, apresentou proposta sobre reunir informações a respeito dos recursos naturais globais a partir de um programa de satélites de sensoriamento remoto (*NASAa*, 2020).

Embora satélites climáticos monitorassem a atmosfera terrestre desde 1960, sendo eles considerados de extrema utilidade, a coleta de dados de superfície a partir do espaço por civis não era apreciada tanto pelo Departamento de Defesa quanto pelo Departamento de Finanças dos Estados Unidos, em função de custos e sigilo de informações. Contudo, como resposta

inicial metódicas investigações sobre SR com instrumentos montados em aviões foram iniciadas pela *National Aeronautics and Space Administration (NASA)* em 1965. No ano seguinte Stewart L. Udall, secretário do Departamento de Interior, anunciou que o departamento procederia com o programa de satélite de observações da Terra convencido pela *USGS (NASAa, 2020)*.

Enquanto manobras políticas coagiam a aceleração da produção do programa pela *NASA*, o orçamento sofria contrações e as agências que seriam usuárias finais dos produtos resultantes (Departamento de Agricultura e Departamento de Interior) não entravam em acordo sobre que tipo de sensor deveria ser construído, atrasando o processo construtivo do satélite. Somente em 1970 a agência espacial seria autorizada a proceder com a construção, finalizando-a de forma memorável em dois anos (*NASAa, 2020*).

### **3.2.2 Landsat 1, 2 e 3**

No dia 23 de julho de 1972, o primeiro satélite civil com explícito propósito de estudar e monitorar aspectos naturais do planeta foi enviado ao espaço sob a alcunha inicial de *Earth Resources Technology Satellite (ERTS)*, sendo posteriormente renomeado para *Landsat 1*, que carregara embarcado consigo dois instrumentos para realizar seu objetivo, sendo eles: o sistema de câmeras *Return Beam Vidicon (RBV)*, construído pela *Radio Corporation of America (RCA)*, e o *Multispectral Scanner (MSS)*, construído pela *Hughes Aircraft Company*. O *ERTS* foi construído embasado em plataformas de satélites climáticos, por este motivo sua estrutura se assemelha a dos satélites meteorológicos *Nimbus (NASAb, 2020)*.

Figura 2. Esquema do satélite *ERTS (Landsat 1)*

Fonte: NASAAb, 2020

Por conta de uma breve perda de controle de altitude causada por um pico de energia que teve como fonte o sistema *RBV*, e pela qualidade inferior apresentada nos dados deste equipamento em comparação aos *MSS*, o *RBV* que inicialmente seria o instrumento principal da missão tornou-se secundário. O *MSS* era um instrumento altamente experimental que armazenava dados em quatro bandas espectrais (uma em verde, uma em vermelho e duas bandas em infravermelho) surpreendeu o corpo técnico envolvido no projeto com o desempenho demonstrado em seus dados. Supervisionando trezentos pesquisadores dos mais diversos ramos da ciência, sendo aproximadamente um terço deles cientistas internacionais, a *NASA* buscou compreensão sobre os dados, utilidade e aplicações potenciais para a nova tecnologia na área específica de cada um dos especialistas (*NASAAb*, 2020).

O *Landsat 1* se manteve em operação até janeiro de 1978, superando sua perspectiva de duração projetada em cinco anos. As informações resultantes dessa missão excederam todas as expectativas quanto à qualidade e impacto de aplicação, o que permitiu a continuidade do projeto antes mesmo do término das operações do primeiro satélite, embora o projeto ainda fosse considerado experimental (*NASAAb*, 2020).

Dois anos e meio após o lançamento do *Landsat 1*, o *Landsat 2* foi lançado em órbita na data de 22 de janeiro de 1975, carregando os mesmo sensores que seu predecessor (o *RBV* e o *MSS*). Depois de sete anos de serviço, no dia 25 de fevereiro de 1982, apresentou problemas no controle de rotação, sendo removido de operação. Foi oficialmente descontinuado em 27 de julho de 1983 (*NASAc*, 2020).

Figura 3. Arte conceitual do satélite *Landsat 2* em órbita



Fonte: NASA, 2020

O sucesso científico e tecnológico do programa, associado a pressões políticas e econômicas conduziram para a decisão de comercialização de um satélite *Landsat*. Com isso o controle de operação foi retirado da *NASA* e entregue a *National Oceanic and Atmospheric Administration (NOAA)*, agência encarregada das operações dos satélites climáticos. Oficialmente, isso aconteceu com a assinatura de uma Diretriz Presidencial da data de 16 de novembro de 1979, contudo, na prática essa transferência só viria a se concretizar no ano de 1983 (*NASA*, 2020).


Anteriormente, em 5 de março de 1978 era enviado a órbita o terceiro satélite do programa, o *Landsat 3*. Este satélite carregava os mesmos sensores que os anteriores com algumas modificações. O *RBV* agora utilizava duas câmeras sensíveis a uma única faixa espectral que ia do comprimento de onda verde ao infravermelho-próximo (0,505 – 0,750  $\mu\text{m}$ ), com uma resolução espacial melhorada de 38 m. O *MSS*, no entanto, continuou a coletar imagens utilizando quatro bandas espectrais, assim como suas versões anteriores. Embora isso tenha acontecido somente em razão de uma falha ocorrida no canal de banda termal, projetada para ser a quinta, logo após o lançamento. Essa missão foi colocada em modo de espera em março de 1983, sendo desativada em setembro do mesmo ano (*NASA*, 2020).

Figura 4. Satélite *Landsat 3*

Fonte: NASA, 2020

### 3.2.3 Landsat 4

O primeiro satélite da série a apresentar mudanças significativas entre os primeiros lançados foi o *Landsat 4*. Com o lançamento ocorrido na data de 16 de julho de 1982, este não mais carregava o equipamento *RBV*. Agora junto ao sensor *MSS*, um novo equipamento carregado pelo satélite proporcionava uma faixa de rastreamento mais ampla em relação ao espectro eletromagnético, com maior embasamento científico, e melhor resolução espacial. Esse instrumento, nomeado *Thematic Mapper (TM)*, coletava imagens a partir de sete bandas espectrais, sendo elas: azul, verde, vermelho, infravermelho-próximo, duas bandas de infravermelho-médio e infravermelho termal (NASAe, 2020).

Figura 5. Modelo do satélite *Landsat 4*

Fonte: NASAe, 2020

Essa missão sofreu a perda de dois de seus painéis solares e seus dois transmissores de comunicação de dados com as bases em solo logo em seu primeiro ano de operação. O recebimento dos dados coletados após este evento só foi possível depois de ser posto em

atividade o *Tracking and Data Relay Satellite System (TDRSS)*, que recebia os dados do *Landsat 4* a partir de transmissões na banda *Ku*, repassando então para as bases em solo. Após o lançamento de seu sucessor passou a transmitir os dados via banda *X* do sensor *TM* presente nele, até que em 1987 esta banda teve que ser desativada devido a anomalias de energia. Voltou a enviar dados com o sistema *TDRSS* até o ano de 1993, quando por falhas ocorridas nesse no sistema o fizeram perder a capacidade de comunicar seus dados. O satélite foi mantido em órbita para registro de comando de telemetria e referencia espaço-temporal (*data tracking*) até ser desativo em 2001 (NASAe, 2020).

Embora construído e lançado pela *NASA*, a operação da missão *Landsat 4* foi supervisionada inicialmente pela *NOAA*, a qual contratou no ano de 1984 a empresa privada *Earth Observation Satellite Company (EOSAT)* para exercer os serviços operacionais. Em 1998 o gerenciamento do programa foi repassado da *NOAA* para a *USGS*, porém as operações mantiveram-se sobre responsabilidade do setor privado até meados de 2001 quando a *Space Imaging*, antiga *EOSAT*, retornou o contrato operacional ao governo americano (NASAe, 2020).

### **3.2.4 Landsat 5**

O satélite *Landsat 5* foi enviado ao espaço no dia primeiro de março de 1984, sendo uma cópia do projeto *Landsat 4*, carregando exatamente os mesmos tipos de equipamentos. Esse foi o último satélite da série enviado originalmente sob a autoridade da *NASA*, pois naquele mesmo ano o Congresso americano decidiu pela privatização dos satélites de observação terrestre. Como dito anteriormente *EOSAT* foi a empresa escolhida pela *NOAA* para realizar o gerenciamento do programa *Landsat*, ficando encarregada de arquivar, coletar e distribuir as imagens. Ela também seria responsável pela construção, lançamento e operação dos dois satélites sucessores do programa, com subsídios governamentais (NASAf, 2020).

Os anos de privatização criaram alguns problemas, pois *EOSAT* se viu com pouca liberdade comercial devido à legislação constituída em 1984 e com isso ocorreu uma intensa elevação nos preços das imagens que saíram de US\$ 650,00 para US\$ 4400,00, além de restrições à redistribuição (NASAf, 2020).



Figura 6. Desenho do satélite *Landsat 5*



Fonte: NASAf, 2020

Os transmissores *TDRSS* do *Landsat 5* vieram a falhar em 1988 e 1992, impossibilitando que seus dados fossem recebidos fora do território americano. Essa missão não possuía dispositivos de armazenamento integrados para transmissão tardia dos dados, o que causou muita restrição. E assim, enquanto o monopólio americano sobre os dados *Landsat* (de forma conjunta à sua prática de preços) aumentou em 600% a viabilidade de sua produção, acabou por deixar muitos usuários sem acesso aos dados (NASAf, 2020).

Por esse motivo àqueles que precisavam dos dados passaram a recorrer a produtos de distribuição gratuita com menor resolução advinda de satélites meteorológicos. Até que em 1986 é lançado o satélite comercial Francês *Satellite Pour l'Observation de la Terre (SPOT)*, o qual quebra o monopólio americano de imagens orbitais (NASAf, 2020).

Durante o período administrativo da *EOSAT*, os padrões de cobertura do *Landsat* definharam, já que agora o programa operava de forma comercial não faria sentido adquirir dados que não tivessem consumidores imediatos. Uma grande quantidade de observações entre os anos de 1984 e 1999 foram perdidas. Logo, esse período descaracterizou a proposta inicial do programa, uma vez que uma verdadeira missão científica coleta tantos dados quanto possível visando estudos científicos posteriores. Além disso, nesse período os sistemas de calibragem e caracterização dos satélites do programa expiraram (NASAf, 2020).

Devido aos terríveis resultados da privatização, ocorreu uma mobilização por parte do Congresso americano, com apoio do vice-presidente do país, sob o clamor de pesquisadores usuários dos dados do programa para que o controle das operações fosse devolvido ao governo. Em 2001 o controle de operações retorna oficialmente para o governo federal, assim como os direitos de comercialização e distribuição dos dados do *Landsat 4* e *Landsat 5*, ficando estes sob responsabilidade da *USGS*.


Prosseguindo a saga do *Landsat 5*, em agosto de 1995 o sensor *MSS* é desligado. Depois, em novembro de 2011 o sensor *TM* tem sua aquisição de imagens interrompida em consequência da deterioração de componentes eletrônicos ocorrida de forma célere. Meses mais tarde o *MSS* é religado e reconfigurado para que seus dados brutos fossem assimilados pela a base de solo (NASAf, 2020).

A desativação do *Landsat 5* foi anunciada em 21 de dezembro de 2012 pela *USGS* após a falha do giroscópio sobressalente. Em janeiro de 2013, seus instrumentos foram desligados e o satélite foi direcionado a uma órbita mais baixa, em junho seu combustível excedente foi utilizado, sendo seu último comando de desligamento recebido em 5 de junho. E assim, o satélite projetado para durar três anos permaneceu em atividade por 28 anos e 10 meses, entregando dados de alta qualidade da superfície terrestre em escala global (NASAf, 2020).

### 3.2.5 Landsat 6

No dia 5 de outubro de 1993, o satélite *Landsat 6*, propriedade da então empresa administradora do programa, *EOSAT*, não alcança a velocidade precisa para chegar a órbita e falha em seu lançamento. O satélite possuía a bordo o sensor *Enhanced Thematic Mapper (ETM)*, o qual registrava dados nas mesmas bandas que seus predecessores *Landsat 4* e *5*, com o adicional de uma oitava banda sensível do verde até a infravermelho-próximo, com resolução espacial de 15 m, sendo conhecida como banda pancromática. Uma vez que o *Landsat 6* não foi exitoso, o programa passou pelo risco de uma iminente interrupção de cobertura, não fosse pela resiliência do *Landsat 5* (NASAg, 2020).

Figura 7. Esboço do *Landsat 6* em órbita



Fonte: NASA, 2020

### 3.2.6 Landsat 7

Em 15 de abril de 1999 foi obtido sucesso no lançamento do satélite *Landsat 7*, o primeiro de propriedade do governo americano após um longo período de administração privada do programa. Esse satélite carregava consigo o sensor *Enhanced Thematic Mapper Plus (ETM+)*, um equipamento baseado no sucesso do *TM* o qual possui elementos adicionais como uma banda pancromática com resolução espacial de 15 m, calibração radiométrica absoluta de 5% feita no próprio equipamento e abertura completa, uma banda de infravermelho termal com 60 m de resolução espacial e um gravador de dados inserido dentro do console (NASA, 2020).

Figura 8. Satélite *Landsat 7*



Fonte: NASA, 2020

Tais características fizeram do *Landsat 7* um eficiente instrumento para estudos de mudanças globais, monitoramento da cobertura e mapeamento de amplas áreas. Além disso, em função dos rígidos padrões de calibração, as medições realizadas pelo satélite foram consideradas as mais acuradas comparadas com as medições em solo, dentre aqueles em órbita à sua época (NASA, 2020).


Em consequência da excelência de qualidade dos dados, um robusto esquema de aquisição de dados global e uma redução nos preços dos produtos (retornados aos US\$ 600,00), a missão Landsat 7 fez aumentar o número de usuários dos dados do programa. Em 2009 os dados do programa se tornaram gratuitos, conseqüentemente seu uso aumentou 60 vezes (NASAh, 2020).

No entanto, em maio de 2003 uma falha em um componente de hardware do satélite fez com que perdesse o *Scan Line Corrector (SLC)*, e a partir de então a linha de visão do sensor capta apenas um padrão de “zigzag” sobre a superfície terrestre, deixando rastros sem dados nas imagens. Apesar disso, o satélite continua em operação até os dias hoje, graças a soluções de preenchimento de dados elaboradas (NASAh, 2020).

### 3.2.7 Landsat 8

O *Landsat 8 (L8)*, pertencente ao terceiro grupo de satélites do programa (agrupamento diferenciado pelo melhoramento nos métodos de calibração dos sensores e adição de novas bandas), foi inicialmente nomeado “Missão de Continuidade de Dados *Landsat*”, durante sua fase de construção, lançamento e calibração orbital realizadas pela NASA. Ele teve seu lançamento executado no dia 11 de fevereiro de 2013, partindo da Base da Força Aérea de Vandenberg, Califórnia, em um foguete Atlas-V 401, estando efetivamente em operação normal apenas a partir de 30 de maio de 2013. O L8 carrega consigo os sensores *Operational Land Imager (OLI)* e o *Thermal Infrared Sensor (TIRS)*, capazes de imagear em uma largura de faixa equivalente a 185 km (YOUNG *et al.*, 2017; USGS, 2020; NASAi, 2020).

Figura 9. Satélite *Landsat 8*



Fonte: NASAi, 2020

O sensor *OLI* é um scanner do tipo *push-broom* com um telescópio de quatro espelhos, que possui nove bandas, sendo oito multiespectrais com resolução espacial de 30 m e uma

pancromática com resolução espacial de 15 m. Já o sensor *TIRS* possui duas bandas referentes ao comprimento de onda do infravermelho termal com resolução espacial de 100 m, disponibilizadas com reamostragem para 30 m e correção com as imagens do sensor *OLI*. As imagens dos sensores presentes no *L8* possuem resolução radiométrica de 12 bits e resolução temporal de 16 dias, mais detalhes na **tabela 1** (YOUNG *et al.*, 2017; USGS, 2020; NASAi, 2020).

Tabela 1. Características das bandas presentes no *Landsat 8*

Bandas	Nome	Comprimento de onda ( $\mu\text{m}$ )	Resolução espacial (m)
B1	Aerossol costeiro	0,433 - 0,453	30
B2	Azul	0,450 - 0,515	30
B3	Verde	0,525 - 0,600	30
B4	Vermelho	0,630 - 0,680	30
B5	Infravermelho próximo	0,845 - 0,885	30
B6	Infravermelho de ondas curtas 1	1,560 - 1,660	30
B7	Infravermelho de ondas curta 2	2,100 - 2,300	30
B8	Pancromática	0,500 - 0,680	15
B9	Cirrus	1,360 - 1,390	30
B10	Infravermelho termal 1	10,60 - 11,19	100 (30) <sup>1</sup>
B11	Infravermelho termal 2	11,50 - 12,51	100 (30) <sup>1</sup>

Fonte: USGS, 2020

Para serem úteis em certas análises ecológicas, as imagens devem ser pré-processadas para contabilizar os efeitos provocados pelos sensores, pelo sol, pela atmosfera e pelo relevo local. Contudo, cada processo executado altera os valores dos dados originais, aumentando a possibilidade de inserção de erros. A determinação do nível apropriado de pré-processamento é uma barreira significativa para aqueles que possuem pouca ou nenhuma experiência com as técnicas necessárias para o pré-processamento desses dados, as quais são numerosas e constantemente alteradas (YOUNG *et al.*, 2017).

### 3.3 Correção geométrica

O processo de correção geométrica é composto por georreferenciamento (posicionamento da imagem em sua devida localização geográfica) e ortorretificação

<sup>1</sup> Reamostragem dos pixels de resolução espacial originalmente em 100 m para 30 m por convolução bicúbica

(ajustamento ao relevo e às direções da localização do *pixel*) para determinar a posição exata de uma imagem, podendo essa posição ser relativa a um sistema de referência, topografia local ou outros tipos de dados que se pretenda utilizar em uma análise (YOUNG *et al.*, 2017; USGS, 2020).

Os produtos *Landsat Level-1* são precisamente georreferenciados e ortorretificados através de um processo sistemático que envolve pontos de controle no solo e modelos digitais de elevação (MDE), sendo eles denominados “*terrain-corrected*”, ou seja, corrigidos pelo terreno. Essas imagens são classificadas em grupos (*tiers*), baseadas em qualidade e nível de pré-processamento (YOUNG *et al.*, 2017; USGS, 2020).

Observando a um desses grupos, nota-se que no *Tier 1* estão presentes as imagens que apresentam georreferenciamento consistente com erro médio quadrático radial (EMQ ou *RMS*) menor ou igual a que doze metros (menos da metade de um *pixel* da imagem), estando esse grupo apto para análises de séries temporais na escala do *pixel* (YOUNG *et al.*, 2017; USGS, 2020).

### **3.4 Correção radiométrica**

A correção radiométrica é o pré-processamento, ou sequência de pré-processamentos utilizados para correção de deformações nos dados provocados por efeitos referentes à luz solar, aos sensores e a topografia local, podendo ser realizada de forma absoluta ou relativa. Pela forma absoluta são obtidos valores corrigidos para os *pixels* que se caracterizam por serem aproximações dos valores reais. Os produtos que passam por esse pré-processamento podem ser usados para comparações entre imagens no mesmo nível de refinamento. Certos níveis de correção absoluta são melhores para a comparação entre imagens que outros, como por exemplo, a reflectância de superfície que apresenta melhor nível de comparação que a radiância ao nível do sensor (YOUNG *et al.*, 2017; USGS, 2020).

Os números digitais dos produtos *Landsat Level-1* disponibilizados são de fato valores de radiância reescalados para a amplitude dos níveis de *bits*. Para reaver os valores de radiância são utilizados os parâmetros registrados nos metadados (*.MTL*) referentes ao procedimento inverso, em um processo linear, o que revela que somente essa etapa de correção, embora mandatória, não deve ser empregada sem as posteriores para análises (YOUNG *et al.*, 2017; USGS, 2020).

A etapa seguinte seria a correção solar, que leva em consideração a influência da direção do sol sobre o terreno no momento do imageamento. Correções solares transformam os dados de radiância em reflectância no topo da atmosfera (*TOA*) ao incorporar a irradiância solar, a distância entre o sol e a terra, e o ângulo de elevação solar aos cálculos. Esses dados variam conforme o dia e a hora de aquisição da imagem, como também pela latitude do local. Os valores de *TOA* são proporções de radiação recebida refletida pela superfície na intensidade que ela é captada após passar pela atmosfera. Esse processo também utiliza metadados referentes ao momento da captura das imagens presentes no arquivo *.MTL* (YOUNG *et al.*, 2017; USGS, 2020).

### 3.5 Correção atmosférica

Partículas de gases, vapores de água e aerossóis são algumas das possíveis interferências encontradas na atmosfera pelas ondas eletromagnéticas captadas dos alvos na superfície terrestre. A correção atmosférica é aplicada objetivando anular ou ao menos mitigar os efeitos dessas interferências, pois muitas delas variam demasiadamente entre localidades e momentos o que dificulta a aplicação de correções em imagens *Landsat* (YOUNG *et al.*, 2017; USGS, 2020).

Esse é um pré-processamento mandatório quando se pretende comparar múltiplas imagens e sem a aplicação uma correção relativa entre elas. Existem inúmeros métodos de correção atmosférica na literatura, desde os mais simples como o *Dark Object Subtraction (DOS)*, que se utiliza de dados do interior da imagem, até os mais complexos como o *Landsat Ecosystem Disturbance Adaptive Processing System (LEAPS)*. Os procedimentos mais complexos são mais acurados, contudo demandam um maior número e melhor qualidade de dados, além de maior expertise por parte do analista para evitar a inserção de erros, logo é recomendável utilizar produtos já corrigidos e abertamente distribuídos (YOUNG *et al.*, 2017; USGS, 2020).

As *Landsat High-Level products* são imagens previamente pré-processadas pela *USGS* além das especificações padrão das imagens *Landsat Level-1*, eliminando a necessidade de realização de certos procedimentos por parte do usuário final. Os produtos mais notáveis são as imagens de reflectância de superfície, que passaram pelas etapas de transformação de números digitais em radiância, depois para reflectância de topo de atmosfera e por fim para reflectância de superfície utilizando parâmetros atmosféricos e um modelo digital de elevação. Além disso, no conjunto de imagens desse produto está presente uma banda

qualidade com identificação de nuvens, sombras de nuvens, e água (YOUNG *et al.*, 2017; USGS, 2020).

### 3.6 Landsat 8 Surface Reflectance Code (LaSRC)

Um software especializado chamado *Landsat 8 Surface Reflectance Code (LaSRC)*, desenvolvido pela NASA, pelo Dr. Eric Vermote e pela *Goddard Space Flight Center (GSFC)* recebeu adaptações realizadas pela organização da USGS para executar a produção dos *Landsat 8 Surface Reflectance (L8sr)*. No processo o *LaSRC* recebe como entrada os dados brutos da missão e calcula a Reflectância de Topo de Atmosfera (*TOA*) e o Brilho de Temperatura (*BT*) utilizando os parâmetros de calibração contidos nos metadados. Então, as rotinas construídas para a realização da correção atmosférica são aplicadas aos produtos (*TOA* e ao *BT* do *L8*), fazendo uso de dados de entrada auxiliares como vapor de água, ozônio e espessura ótica de aerossol (*AOT*) adquiridos a partir do *Moderate Resolution Imaging Spectroradiometer (MODIS)* e modelo de elevação digital derivado do *GTOPO5* para calcular a reflectância de superfície (USGS, 2019).

Figura 10. Exemplo de correção atmosférica realizada pelo *LaSRC*: à esquerda imagem em Reflectância do Topo da Atmosfera (*TOA*); à direita imagem em Reflectância de Superfície (*SR*)



Fonte: USGS, 2019

### 3.7 Índices de Vegetação

As estratégias de monitoramento das alterações naturais, ou aquelas com origem nas atividades humanas sobre os diversos ambientes do sistema Terra podem ser compostas por índices de vegetação (IV's) calculados a partir de dados de SR. Os IV's são modelos matematicamente desenvolvidos, que transformam as características dos pixels presentes nas



imagens, sendo capazes de realçar feições de cobertura vegetal, permitindo sua avaliação quantitativa e qualitativa relacionando verdade de campo e assinaturas espectrais. Ainda que vastamente utilizados, os índices não podem ser considerados absolutos, uma vez que a influência de diversos fatores como umidade, textura do solo, turbidez atmosférica, temperatura, e outros, pode comprometer a demanda por levantamentos mais realistas (DE FRANÇA E SILVA; DA SILVA; ALVES, 2017).

Levando em consideração o livro de Jensen (2009), os IV's indicam abundância relativa e atividade da vegetação verde, sendo expressos por medidas radiométricas adimensionais. De forma ideal os índices devem maximizar a resposta de parâmetros biofísicos da vegetação e se possível linearmente, visando assim a máxima diferenciação possível entre as condições da vegetação a fim de facilitar a calibração dos índices com verdades de campo.

Ainda pela perspectiva de Jensen (2009), para permitir a realização de comparação espaço-temporal os índices devem normalizar ou criar modelos para as ações de efeitos externos à seus alvos como ângulos de visada dos sensores, azimute solar e interferências atmosféricas. Por fim normalizar efeitos internos, como relevo local, variação de solos e substratos abaixo do dossel e distinção entre senescente e fotossinteticamente ativa ou que apresente aquelas que apresentem ramos lenhosos.

Os IVs podem ser caracterizados como sensíveis à concentração do pigmento (clorofila) e estruturais, sofrem ou não influência das propriedades óticas do solo. Muitas pesquisas têm utilizado séries temporais de índices de vegetação para o monitoramento da vegetação como (BORATTO; GOMIDE, 2013; BILLAR et al., 2018) entre outros (SILVA FILHO, 2019). Os índices de vegetação empregados nesse estudo são descritos a seguir.

### **3.7.1 Normalized Difference Vegetation Index (NDVI)**

O *NDVI*, desenvolvido por Rouse *et al.* (1973), é um índice espectral estrutural com correlação linear ao crescimento vegetativo, amplamente utilizado em estudos agrícolas e ambientais (SILVA FILHO, 2019). É um tido como bom indicador de alterações na vegetação em função de desmatamento, apresentando amplitude nos valores dos pixels entre -1 e 1, onde os valores positivos representam vegetação densa e saudável quanto mais se aproximam de 1(AIRES, 2017). Já valores negativos geralmente indicam se tratar de feições não vegetais. Esse índice pode ser calculado a partir da equação 1.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

Onde NIR (*Near InfraRed*) refere-se à energia refletida na região do infravermelho próximo (definida na banda 5 do *Landsat 8*) e RED, a energia refletida na região do vermelho do espectro eletromagnético (definida na banda 4 do *Landsat 8*). Contudo, embora a utilização do *NDVI* seja abrangente na literatura ele possui conhecidas limitações, como a influência exercida pelas condições de fundo (*background*) do solo nas leituras de refletâncias de vegetação esparsa e culturas agrícolas dos satélites (RAMBO *et al.*, 2019).

### 3.7.2 Enhanced Vegetation Index 2 (EVI 2)

O *Enhanced Vegetation Index (EVI)* é resultado de um melhoramento aplicado ao *NDVI*, possuindo maior sensibilidade à variação de dossel, redução de efeitos atmosféricos e fator de ajuste ao *background* do solo. O *EVI 2* é uma modificação proposta por Jiang *et al.* (2008) na qual a utilização da região espectral do azul foi anulada, minimizando as distorções causadas pela atmosfera, significando melhores resultados. Esse índice é calculado a partir da equação 2.

$$EVI2 = \frac{NIR - RED}{NIR + 2,4 \times RED + 1} \times 2,5 \quad (2)$$

Onde NIR refere-se à energia refletida na região do infravermelho próximo (definida na banda 5 do *Landsat 8*) e RED, a energia refletida na região do vermelho do espectro eletromagnético (definida na banda 4 do *Landsat 8*). Este índice comporta-se similarmente ao *EVI* padrão, que demonstra melhor sensibilidade a altas respostas de biomassa (JIANG, 2008).

### 3.7.3 Modified Soil-Adjusted Vegetation Index 2 (MSAVI 2)

O *Soil-Adjusted Vegetation Index (SAVI)* é um índice que considera os efeitos do solo exposto nas análises de imagens e ajusta o *NDVI* quando a superfície não está inteiramente coberta pela vegetação, a partir de um fator de ajuste L que varia de 0 (muito coberta) a 1 (descoberta). O *Modified Soil-Adjusted Vegetation Index 2 (MSAVI 2)*, proposto por Richardson and Wiegand (1977), é um índice de formula mais simples derivado do *SAVI* padrão, sendo principalmente utilizado em análises de crescimento de plantas, pesquisas sobre desertificação, cálculos estimativas de índice de área foliar, estimativa de campos de pastos

naturais, análise de matéria orgânica do solo, monitoramento de inundações e análise de erosão dos solos (Xue e Su, 2017). Seu cálculo é expresso pela equação 3.

$$MSAVI 2 = (2 \times NIR + 1) - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - RED)} \quad (3)$$

Onde NIR refere-se à energia refletida na região do infravermelho próximo (definida na banda 5 do *Landsat 8*) e RED, a energia refletida na região do vermelho do espectro eletromagnético (definida na banda 4 do *Landsat 8*).

### 3.7.4 Normalized Difference Water Index Gao (NDWI Gao)

O *NDWI Gao* é um índice espectral equacionado em Gao (1996) que trata do acesso à umidade presente no ambiente. Em regiões áridas e semiáridas é utilizado para o cálculo de estresse hídrico da vegetação, quanto maior o valor do índice representa maior é o conteúdo de água (BILLAR *et al.*, 2017). A equação 4 define o *NDWI*.

$$NDWI Gao = \frac{NIR - MIR}{NIR + MIR} \quad (4)$$

Onde *NIR* refere-se à energia refletida na região do infravermelho próximo (definida na banda 5 do *Landsat 8*) e *MIR* (*Medium InfraRed*), a energia refletida na região do infravermelho médio do espectro eletromagnético (definida na banda 6 do *Landsat 8*).

### 3.7.5 Leaf Area Index (LAI)

O *Leaf Area Index (LAI)* é habitualmente usado para estimar a densidade de área foliar sobre um terreno, tendo sido citado como sendo a área de folhas por unidade de terreno ( $m^2.m^{-2}$ ) Os valores do índice sobrem à medida que aumentam o número de folhas por colmo ou área foliar individualmente, podendo ser definido como a relação entre a área de folhagem e superfície em que ela se faz presente, variando conforme o tipo de vegetação, as disponibilidade hídrica, a sazonalidade e o estagio de desenvolvimento das plantas (GAMEIRO *et al.*, 2017; WATSON, 1947).

As informações adquiridas a partir do índice são de essencial importância em vários aspectos ecológicos como a competição inter e intraespecífica das plantas, níveis de carbono retidos e conservação do solo, demonstrando possuir vasta aplicabilidade (BREDA, 2003).

Para o corrente estudo a equação do *LAI* foi utilizada tendo como base o índice *MSAVI2* como pode ser observado abaixo.

$$LAI = - \frac{\ln\left(\frac{0,69-MSAVI2}{0,59}\right)}{0,91} \quad (5)$$

### 3.8 Climate Hazards Group InfraRed Precipitation with Stations (CHIRPS)

Estimativas de chuva baseadas em satélite podem prover informação abundante especialmente sobre amplas regiões marginalizadas onde a coleta de dados de precipitação convencional é escassa ou ausente. A demanda por produtos de SR de alta precisão baseados em dados de chuva com alta resolução espaço-temporal para diversas temáticas de estudo como irrigação e gerenciamento de recursos hídricos em áreas remotas vem aumentando ao longo do tempo, pois atualmente no Brasil faltam redes de medições pluviométricas adequadas para análise de chuvas em grande parte pela baixa cobertura espacial apresentada por estas, sem esquecer-se da grande proporção de dados perdidos e o curto período de registros (PAREDES-TREJO; BARBOSA; KUMAR, 2017).

Corriqueiramente são utilizadas as bandas de infravermelho termal (*TIR*) ou sensores de microondas passivos (*PM*) como dados de entrada de algoritmos de estimativa de chuvas a partir de observações orbitais de satélite. Na maioria dos casos o uso de *PM* obtém melhores resultados para períodos de tempo curtos, enquanto os métodos que utilizam o *TIR* são melhores para longos períodos. Para sobrepujar essas limitações os produtos mais recentes combinam múltiplas dados de vários tipos e múltiplas plataformas, incluindo os já citados, além de observações locais e de modelos de campos de chuvas a fim de melhorar a acurácia dos produtos (PAREDES-TREJO; BARBOSA; KUMAR, 2017).

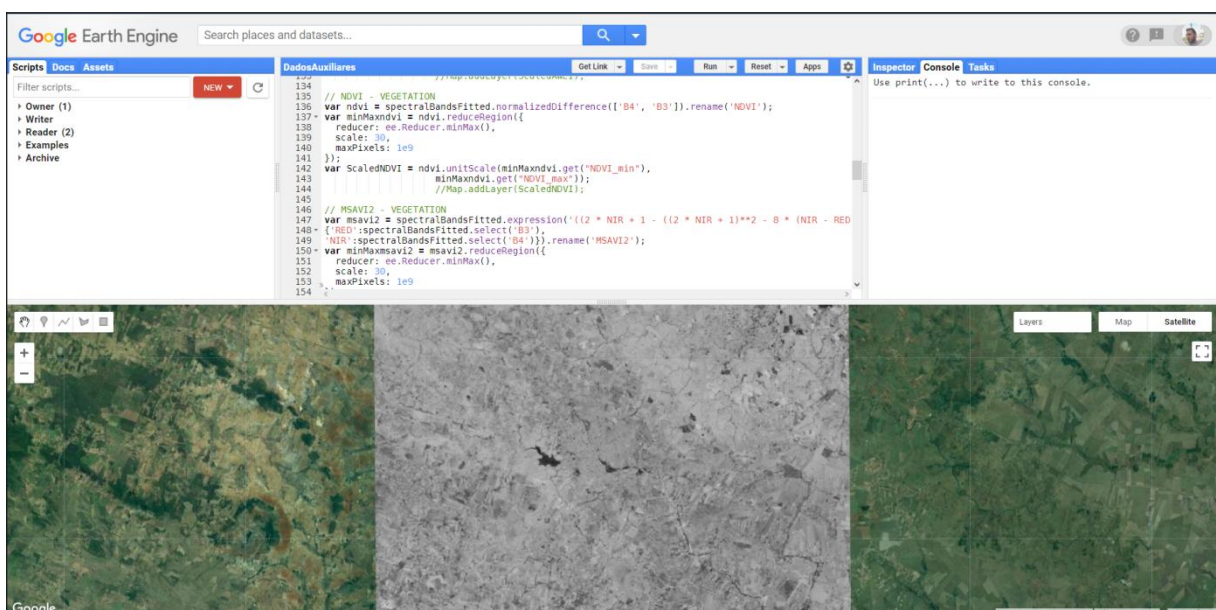
Com registro de dados que começa em 1981 indo até a data presente, o conjunto de imagens de precipitação *Climate Hazards Group InfraRed Precipitation with Stations* (CHIRPS), desenvolvido para análise de tendências e monitoramento sazonal de inundações é disponibilizado na escala espacial de 0,05° (latitudinal e longitudinal, cerca de 5,3 km) e resolução temporal diária, acumulado de 5 dias ou 10 dias. Sua versão mais recente (CHIRPS V.2) é criada a partir de imagens *TIR* e baseada em regressão linear de dados TRMM, os quais não serão comentados nesse trabalho, depois normalizados e multiplicados por dados climatológicos, depois esses resultados são misturados com dados de estações pluviométricas.

Sua cobertura é quase global, indo de 50° S a 50° N e 180° E a 180° O (PAREDES-TREJO; BARBOSA; KUMAR, 2017).

### 3.9 Plataforma de processamento em nuvem *Google Earth Engine*

O *Google Earth Engine (GEE)* é uma plataforma de processamento de dados em nuvem lançada no ano de 2013, que vem se mostrando como um proeminente instrumento na busca por geração de informação a partir de dados de sensoriamento remoto de forma menos onerosa. Ela possui em seu catálogo *online* uma variedade enorme de produtos, incluindo imagens do programa de satélites *Landsat* desde o ano de 1972 (AIRES *et al.*, 2017). Para utilizar a plataforma o usuário necessita apenas ter acesso à *internet* e possuir uma conta de *e-mail* do provedor *Google* com a qual realiza o *login* na interface (figura 11).

Figura 11. Interface do Code Editor do *Google Earth Engine*



Fonte: Autor, 2020

Nos últimos anos vem crescendo o número de pesquisas realizadas utilizando a plataforma principalmente com relação à temática ambiental com ênfase para trabalhos em escala planetária. Essa procura é justificada pela considerável redução de tempo de processamento, redução de armazenamento de dados e maior flexibilidade que ela possibilita.

Em 2013 Hansen realizou um mapeamento florestal em escala planetária monitorando desflorestamento e recuperação de áreas utilizando 20 *terapixels* de dados *Landsat* processado na ordem de dias, os quais se processados em uma única máquina local demandaria dessa 15 anos para alcançar resultados (apud AIRES *et al.*, 2017).

É oportuno ressaltar outros trabalhos que influenciaram na decisão de utilizar a plataforma como meio de execução desta pesquisa, entre eles Diogo *et al.* (2019) avaliou a dinâmica da fenologia da vegetação natural, agricultura e pastagem no sul de Angola entre 2001 e 2018 a partir de séries temporais de *NDVI* e evapotranspiração (ET) calculados a partir de dados do sensor orbital *MODIS* pela plataforma *Google Earth Engine*. Neste trabalho os autores demonstraram a capacidade da plataforma em produzir informação a partir de séries de temporais para vegetação do tipo agrícola.

Outra pesquisa foi a de Pessoa *et al.* (2019) que quantificou o impacto da seca sobre os recursos hídricos na microrregião da Serra da Teixeira – PB, utilizando imagens do satélite *Landsat 8* em datas representativas do início das estações do ano na plataforma *Google Earth Engine* para ressaltar os corpos d'água. Foi possível observar a capacidade da utilização da plataforma para questões referentes aos impactos climáticos em escala regional.

Becker *et al.* (2019) realizou um mapeamento de uso e cobertura da terra para a bacia hidrográfica do rio São Francisco Verdadeiro (SFV), utilizando como parâmetro o desvio padrão e a mediana da série temporal do índice de vegetação por diferença normalizada (*NDVI*) a partir do *Google Earth Engine*. Estabeleceu que a identificação dos alvos por meio de álgebra e estatísticas dos *rasters* é viável pela programação do *GEE*.

Outros trabalhos ponderados na composição da metodologia e análise dos resultados podem ser encontrados ao longo da monografia.

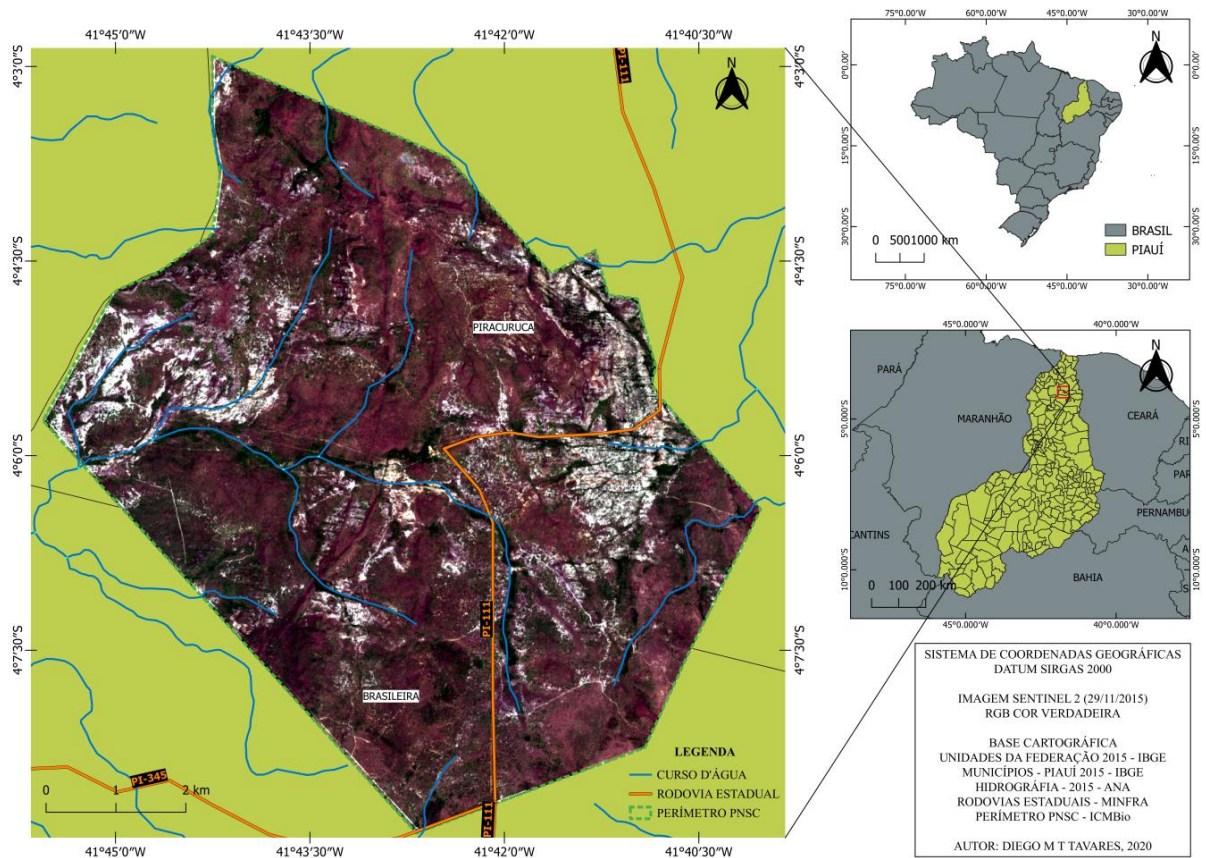
## 4 MATERIAL E MÉTODOS

### 4.1 Localização e caracterização da área de estudo

O Parque Nacional de Sete Cidades (PNSC) trata-se de uma unidade conservação que foi criado pelo Decreto Federal nº 50.744 na data de 08 de junho de 1961, com os objetivos de preservar a diversidade ecológica, dada sua expressiva variabilidade e importância, bem como as belezas naturais presentes na região, além de viabilizar pesquisas científicas, fomentar a educação ambiental e o ecoturismo (IDBF, 1979).

Está localizado entre os municípios de Brasileira e Piracuruca, nordeste do estado do Piauí, se estendendo por uma área equivalente a 6.221,48 ha, confinada em um perímetro de 36,2 km (IDBF, 1979). Suas principais vias de acesso são a rodovia estadual PI-111 a partir da BR-222, no intervalo que comunica Piriipiri à Fortaleza, e a PI-345 a partir da BR-343, no trecho entre Teresina e Parnaíba. É delimitado pelo retângulo envolvente de coordenadas geográficas: 04°08'54,60" S, 41°45'33,56" O e 04°02'55,25" S, 41°40'01,32" O, georreferenciadas ao sistema de referência SIRGAS 2000, representado na **figura12**.

Figura 12. Mapa de localização



Fonte: Autor, 2020

De acordo com a pesquisa de Oliveira *et al.* (2010), o clima é classificado como tropical semiúmido úmido, com significativa deficiência hídrica invernal e pequena amplitude térmica anual ( $C_2w_2A'_{4a}$ ). E, segundo o estudo de Santos *et al.* (2016), a precipitação anual média é registrada em torno de 1.500 mm em função dos efeitos da Zona de Convergência Intertropical (ZCIT).

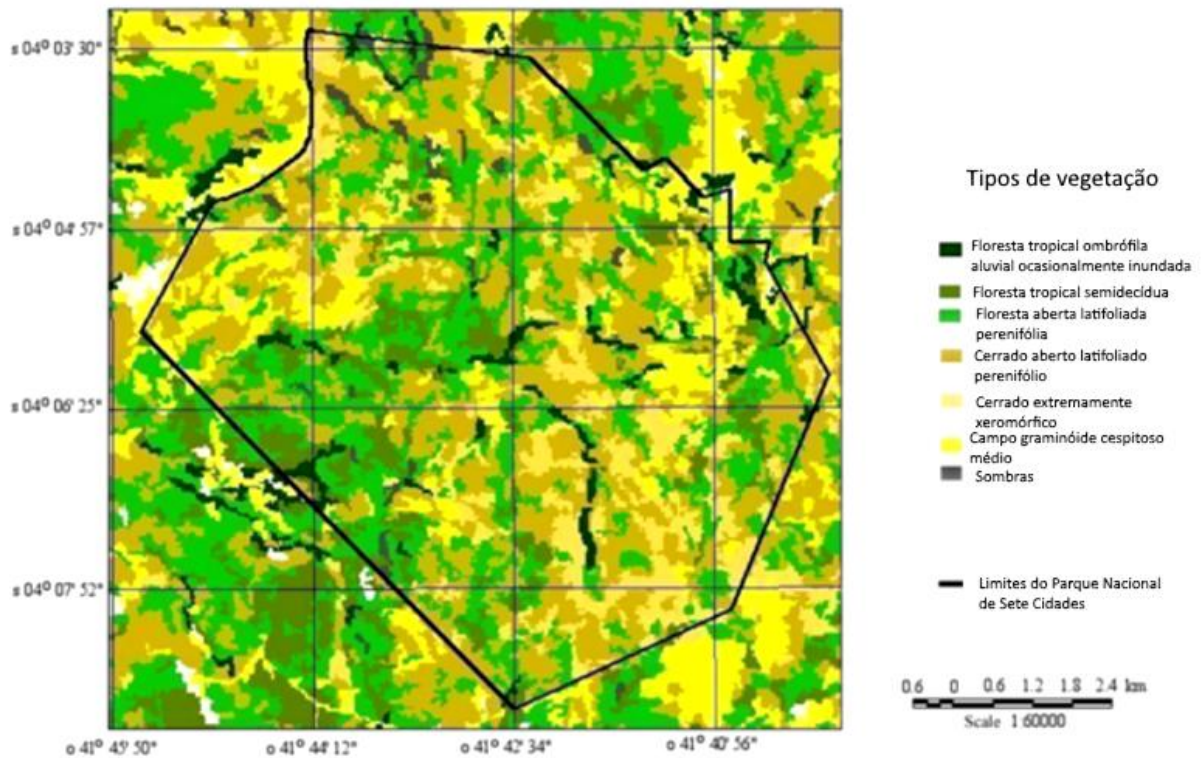
Sua vegetação, desde 2001, é classificada como pertencente ao bioma Caatinga, de acordo com o Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio, 2020). Contudo, como observado em Oliveira *et al.* (2010), por tempos, não houve consenso entre pesquisadores quanto a esta classificação, uma vez que o parque está encravado em uma zona de transição entre biomas, composta por mosaico de diferentes tipos de vegetação, onde o Cerrado é predominante.

Em Oliveira *et al.* (2007), foi realizado o primeiro mapeamento da vegetação do PNSC, confirmando que esta possui matriz de Cerrado. Neste mapeamento, observado na **figura 13**, a paisagem foi caracterizada pelo desenvolvimento de campos graminóides



cespitosos médios, cerrado extremamente xeromórfico, cerrado aberto latifoliado perenifólio, floresta tropical ombrófila aluvial periodicamente inundada, floresta tropical semidecídua e floresta aberta latifoliada perenifólia. Essa variedade vegetal, de acordo com Mendes e Santos (2019), têm como substrato solos do tipo Plintossolo Pétrico, Neossolos Litólico e Neossolos Quartzarênico.

Figura 13. Mapeamento das classes de vegetação do PNSC



Fonte: Oliveira *et al.*, 2007 (legenda com tradução adaptada para o idioma Português)

O parque está situado na bacia sedimentar nomeada como “do Parnaíba”, “do Piauí-Maranhão”, ou “do Meio-Norte”. Estando sobre a formação geológica Cabeças, do grupo Canindé. São observadas na área quatro feições geomorfológicas, sendo elas: afloramentos rochosos maciços e esculpido, formações arenosas (sendo estas duas as mais importantes), pavimentos de blocos e couraças ferruginosas (OLIVEIRA *et al.*, 2010).

O relevo é predominantemente constituído de chapadas planas formando mesas e escarpas abruptas, com altitude variando de 100 a 300 m, onde em sua maior cota, na falha do Morro do Cochicho, se delimita o divisor de águas do parque (OLIVEIRA *et al.*, 2010).

Em relação à hidrologia, é de conhecimento que os rios Piracuruca e Matos, que fazem parte da sub-bacia do rio Longá, possuem diversas nascentes pertencentes ao território do

PNSC (OLIVEIRA *et al.*, 2010). Os rios e riachos presentes no interior do parque chegam a secar de forma parcial ou total, de setembro a dezembro, enquanto apresentam as maiores vazões entre janeiro e agosto (IDBF, 1979). Há ocorrência de planícies inundáveis em período chuvoso, formadas a partir de riachos, especialmente a oeste (OLIVEIRA *et al.*, 2010).

#### **4.2 Material e softwares utilizados**

Buscando desenvolver uma metodologia aplicável à temática proposta e as especificidades regionais da Unidade de Conservação (UC) alvo deste estudo, foi realizada pesquisa bibliográfica, a partir de conteúdo nacional e internacional, sobre índices espectrais relacionados ao monitoramento de vegetação e algoritmos elaborados por usuários e desenvolvedores da plataforma *GEE* aplicáveis ao tema.

Nesta etapa foi determinado o intervalo de tempo no qual estaria definido o presente estudo, sendo ele iniciado no começo do inverno (21/06) do ano de 2013 e o finalizado ao término do outono (20/06) do ano de 2015. Esse intervalo foi escolhido por disponibilizar uma quantidade de oito estações climáticas para observação e quantidades de imagem orbitais por estação padronizadas. Depois, foram escolhidos como insumos imagens das coleções *Landsat 8 Surface Reflectance Tier 1 (L8srT1)* e *Climate Hazards Group InfraRed Precipitation with Station Data (CHIRPS)*, ambas pertencentes ao acervo da plataforma. Estas coleções apresentam tratamentos e características satisfatórias para os processamentos e resultados pretendidos nesta pesquisa.

O serviço de armazenamento *Google Drive*, por possuir conexão nativa com a plataforma *GEE*, serviu como intermediário na circulação dos arquivos entre *software* local e a plataforma de processamento em nuvem. Outras ferramentas pertencentes à aplicação, como *Google Spreadsheet* e *Google Documents* foram utilizadas para análise e apresentação dos resultados. Sendo assim, nesta pesquisa, fez uso apenas de *softwares* livres e dados de domínio público.

#### **4.3 Metodologia aplicada**

No endereço virtual do ICMBio, a partir de uma página dedicada ao Parque Nacional de Sete Cidades, foi adquirido o arquivo vetorial em formato *.kml (Keyhole Markup Language)* do perímetro da área de estudo. Uma vez que este formato não é aceito como dado de entrada na plataforma *GEE*, o *software QGIS 3.4* foi utilizado para executar transformação

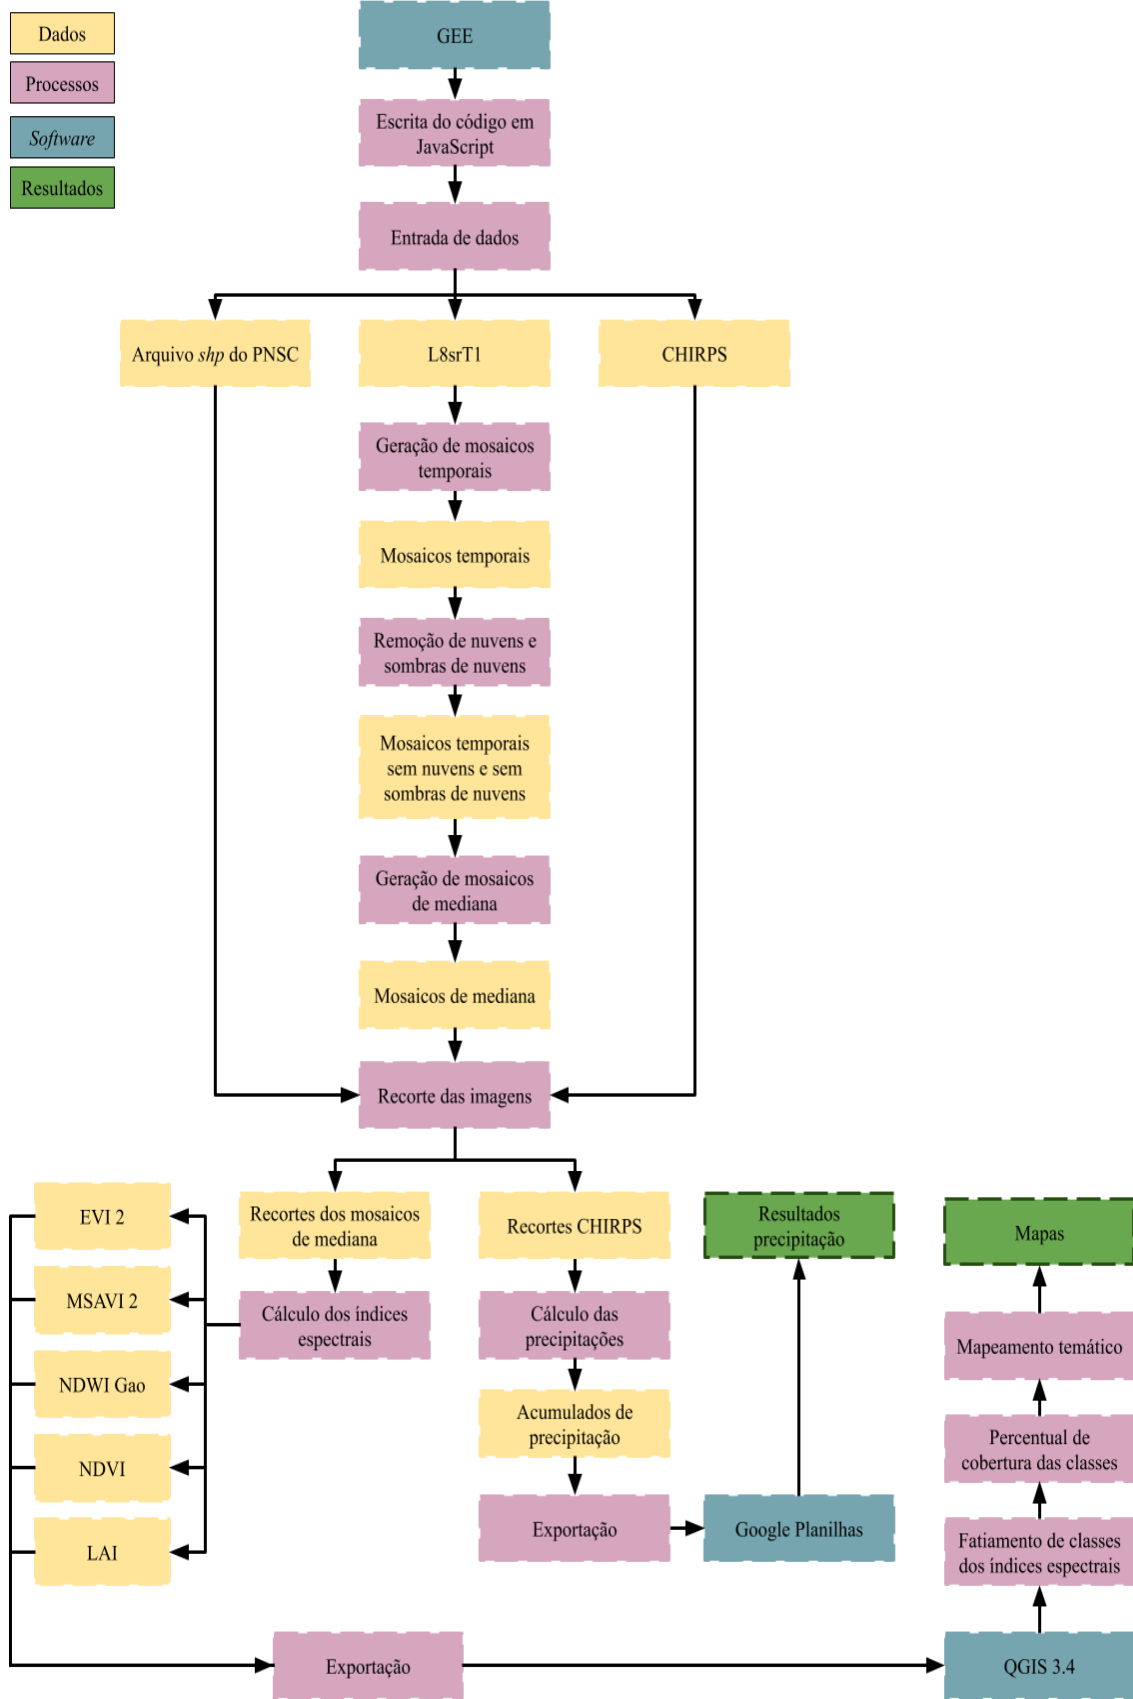
do arquivo para o formato *shapefile* e posteriormente confeccionar mapas temáticos a partir dos índices calculados.

Os procedimentos descritos nesta seção podem ser visualizados no fluxograma apresentado **figura 14**. O algoritmo desenvolvido no *Code Editor* do *GEE* em linguagem *JavaScript*, disponível no *link*<sup>2</sup>, realizou os processos descritos a seguir.

---

<sup>2</sup> <https://code.earthengine.google.com/950861d7fe698aa1040af34a5acece6e>

Figura 14. Fluxograma



Fonte: Autor, 2020

### 4.3.1 Entrada dos dados

#### 4.3.1.1 Dado vetorial

Depois de realizado o *download* do arquivo *.kml* contendo o perímetro do Parque Nacional de Sete Cidades, esse foi aberto no programa *QGIS* 3.4 para conversão ao formato *shapefile* através da ferramenta de seleção e exportação de arquivos nativa da programação do *software*. Durante o processo foi constatado que o perímetro se encontrava georreferenciado ao sistema de coordenadas geográficas, sistema de referência *WGS 84*.

Em seguida, foi realizado o *upload* do *shapefile* para a plataforma *GEE* através da aba *Assets* presente na *interface* do *Code Editor*. Essa aba faz o armazenamento de arquivos diversos (vetoriais, matriciais e alfanuméricos) para que esses fiquem disponíveis para utilização em programas escritos pelo usuário. O que por fim foi feito ao vincular o arquivo a uma variável do algoritmo elaborado nessa pesquisa.

#### 4.3.1.2 Dados matriciais

Uma vez que os dados matriciais (*raster*) definidos na elaboração da metodologia se fazem presentes no catálogo da plataforma de processamento em nuvem, não foi necessário realizar *download* de imagens de fontes externas para a aplicação do estudo, estando eles disponíveis de forma instantânea.

Determinada a variável no algoritmo, toda a coleção *Landsat 8 Surface Reflectance Tier 1 (L8srT1)* foi selecionada como insumo. De mesma forma ocorreu com a coleção de imagens *Climate Hazards Group InfraRed Precipitation with Station Data (CHIRPS)*.

Daí em diante realizou-se alguns processos como a reprojeção dos *L8srT1* que, *a priori*, se encontravam georreferenciados ao sistema de coordenadas UTM zona 28 N, sistema de referência *WGS 84*, para o sistema de coordenadas geográficas, igualando essas imagens aos demais dados da pesquisa. Esta coleção é disponibilizada com seus valores de *pixel* multiplicados por 10000, para que assumam valores inteiros e minimizem o custo computacional de processamentos. No entanto, alguns índices a serem estudados nessa pesquisa apenas são possíveis de serem calculados a partir de valores normalizados de reflectância (entre 0 e 1), logo os pixels da coleção foram divididos por 10000 para alcançar a escala desejada.

### 4.3.2 Geração do mosaico temporal

Foram pesquisadas as mudanças de estação no pagina virtual do Departamento de Astronomia do Instituto de Astronomia, Geofísica e Ciências Climáticas (IAG) da Universidade Estadual de São Paulo (USP). O período considerado para o estudo se define entre as datas de 21 de junho de 2013 e 21 de junho de 2015, respectivamente do início do inverno de 2013 ao término do outono de 2015 (IAG, 2020). Ou seja, dois ciclos de estações climáticas totalizando oito mosaicos temporais representando cada uma delas.

Para separar os dados matriciais referentes a cada estação foram criadas variáveis a partir das coleções originais, onde a função de filtro por datas foi empregada. Cada variável passou a conter um subconjunto de imagens representativas de cada estação.

Observa-se na **tabela 2** abaixo quais os dias de início e término de cada estação, quantos dias cada uma das possui (esses dois primeiros fatores ajudam a definir quais imagens *CHIRPS* pertencem a cada subconjunto, pois a coleção possui resolução temporal diária), quantas imagens *L8srTI* pertencem ao seu conjunto representativo.

Tabela 2. Conjuntos representativos de estações climáticas.

ESTAÇÃO	INÍCIO	TÉRMINO	Qtd DIAS	Qtd <i>L8srTI</i>
Inverno 2013	21/06/2013	22/09/2013	93	6
Primavera 2013	22/09/2013	21/12/2013	90	5
Verão 2013	21/12/2013	20/03/2014	89	6
Outono 2014	20/03/2014	21/06/2014	93	5
Inverno 2014	21/06/2014	22/09/2014	93	6
Primavera 2014	22/09/2014	21/12/2014	90	5
Verão 2014	21/12/2014	20/03/2015	89	5
Outono 2015	20/03/2015	21/06/2015	93	6

Fonte: Autor, 2020

### 4.3.3 Remoção de nuvens e sombras de nuvens

O *C Function of Mask (CFMask)* é um algoritmo de multi passagem que utiliza Árvores de Decisão na detecção de *pixels* que representem nuvens e sombras de nuvens (USGS, 2020). Ele é aplicado no processamento de imagens *Landsat* e sendo a *Quality Assessment Band (QA Band)*, uma banda em codificada em formato *bitmap*, seu produto. Nas imagens *L8sr* essa banda é nomeada como *pixel qa*.

Para a remoção das nuvens e sombras de nuvens foi utilizada um código que interpreta os *bits* da banda *pixel qa* identificando aqueles que representam nuvens (*bit 5*) e sombras de nuvens (*bit 3*) detectadas pelo *CFMask*. Uma vez identificados os *pixels* esses são mascarados e removidos das imagens através de funções nativas do *GEE*.

### 4.3.4 Geração do mosaico (*composite*) de medianas.

Após a remoção dos pixels marcados como nuvem e sombra de nuvem, as cenas consideradas para cada estação climática são reduzidas pelo valor da mediana dos pixels válidos, gerando assim um mosaico representativo para toda estação, também chamado (*composite*). A escolha pelo filtro de mediana ao invés de média é justificada pela remoção dos valores extremos de cada pixel, que por ventura podem ser contaminações ou ruídos do sensor.

De acordo com Ganem *et al.* (2017), as transições rápidas são preservadas pelo filtro de mediana, ao passo que a média atenua as transições por considerar os extremos da janela amostral do conjunto no calculo do valor final do *pixel*.

### 4.3.5 Recorte das imagens

Uma vez prontos os mosaicos de medianas referentes às estações climáticas, esses e as imagens de dados de precipitação foram submetidos à função *clip* implementada no *GEE*. Essa função utiliza um arquivo vetorial como máscara para recortar arquivos *raster* sob uma determinada forma representativa de uma região de interesse. Logo, todas as imagens foram recortadas sob a forma do perímetro georreferenciado do PNSC. Usualmente essa ferramenta é utilizada em outros *softwares* para reduzir a demanda computacional dos estudos, porém neste caso o processo foi desenvolvido apenas para reforçar o foco sobre a área de estudo.

#### 4.3.6 Cálculo das precipitações

Após recortadas sob o delineamento do parque as imagens oriundas da coleção *CHIRPS* resultaram em imagens compostas por partes de pixel, dada a resolução espacial de 0,05 arcos-minutos. Para alcançar os valores de precipitação sobre área do parque foi calculada a média dos valores dos pixels a partir de um filtro implementado na programação, resultando em imagens de média de precipitação diária.

Esses *rasters* já se encontravam agrupados por estação, mas foram também agrupados por mês e postos para análise individualmente (janela temporal diária), a fim de se conhecer o comportamento e a disponibilidade das chuvas para o período de estudo.

#### 4.3.7 Cálculo de índices espectrais

Para realizar a análise ambiental do Parque Nacional de Sete Cidades foram escolhidos alguns índices espectrais observando as características do mesmo. Não havendo sido notada a presença de corpos d'água expressivos em inspeção visual dos mosaicos, índices voltados à delimitação deste tipo de feição foram descartados do estudo. Sabe-se também que a ocorrência de incêndios no parque cessou em meados da década de 1990, tendo seu último registro no ano de 1996 (Oliveira *et al.*, 2010), por conseguinte, índices de monitoramento de queimada também foram descartados. Em função destes fatores a análise foi limitada ao estudo da vegetação a partir dos índices NDVI, EVI 2, MSAVI 2, NDWI Gao e LAI descritos na Fundamentação Teórica.

#### 4.3.8 Exportação dos resultados

Por fim, os resultados foram exportados para o *Google Drive* através de uma das linhas programadas no algoritmo para que as análises das dinâmicas dos índices espectrais fossem realizadas no *Google Spreadsheet*, no caso a relação entre os dados de precipitação e índices de vegetação gerados. Posteriormente, os *rasters* dos índices foram baixados para serem feitos o fatiamento de classes segundo observações feitas na literatura sobre padrões de distribuição, o cálculo percentual de cobertura de cada uma das classes e a confecção de mapas no *QGIS 3.4*.

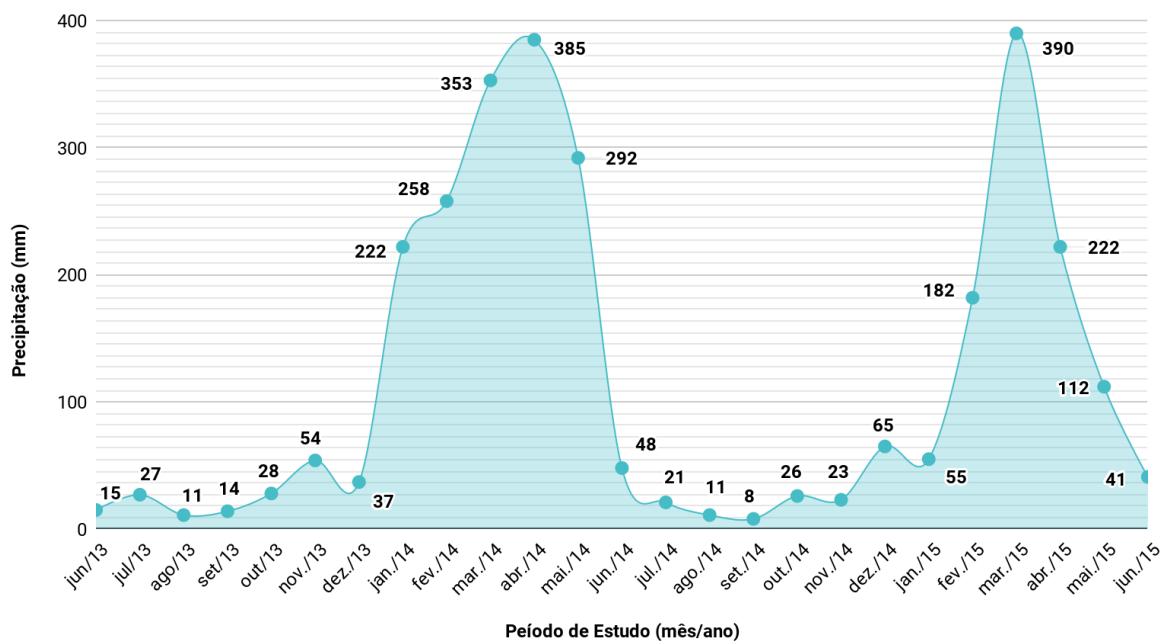


## 5 RESULTADOS E DISCUSSÃO

### 5.1 Análise dos dados pluviométricos

Os dados de precipitação da série *CHIRPS* de resolução temporal diária, foram somados para cada mês do período de estudo e demonstraram que para a área cada ciclo de estações se define em duas partes: seco (do início do terceiro decêndio de junho até o final do segundo decêndio de dezembro, equivalente a inverno e primavera) e chuvoso (do início do terceiro decêndio de dezembro até o final do segundo decêndio de junho, equivalente a verão e outono), como observado na **figura 15**.

Figura 15. Precipitação mensal no período de estudo



Fonte: Autor, 2020


O total de precipitação estimado para todo o período foi 2898,84 mm, sendo 1731,56 mm para o ciclo de estações 2013/2014 e 1167,28 mm para o ciclo 2014/2015. De acordo com os dados da *National Oceanic And Atmospheric Administration (NOAA)*, no ciclo 2013/2014 não houve influência dos eventos *El Niño* e *La Niña*, porém no ciclo 2014/2015 foi registrada fraca influência do evento *El Niño* a partir do conjunto de análise outubro-novembro-dezembro. (NOAA, 2020)

Segundo o trabalho de Santos *et al.* (2016), a média anual de pluviometria registrou 1.222,6 mm anuais em 1998, 1.442,8 mm para 2006 e 1.270,9 mm no ano de 2014, utilizando

dados de estações metrológicas próximas ao PNSC, denotando proximidade aos valores encontrado nos dados de satélite.


Foi constatada uma significativa variação nos dados pluviométricos ao longo do período de estudo. Como é possível notar na **Figura 16**, nos dias 13 de março de 2014 e 29 de maio de 2014, ocorreram, respectivamente, precipitações de 48,562 mm e 41,513 mm, enquanto que o acumulado de julho, agosto e setembro de 2014, juntos, mal alcançou a ordem dos 40 mm.

Figura 16. Dispersão dos dados pluviométricos diários no ciclo sazonal 2013/2014



Como também é possível observar na **Figura 17**, nos meses de março de 2014 e 2015, que somados representaram 25,63% da precipitação total computada nos dois ciclos de estações. Outro ponto a respeito das variações nos dados é visto entre os meses de maio de ambos os ciclos, os quais apresentaram redução de 180 mm nas precipitações. Dentre os 730 dias do período de estudo, 463 dias não apresentaram registro de precipitação.


Figura 17. Dispersão dos dados pluviométricos diários no ciclo sazonal 2014/2015



Fonte: Autor, 2020

Quando agrupados por estações climáticas, na **Figura 18**, os dados *CHIRPS* mostram o outono de 2014 como a mais chuvosa, enquanto o inverno do mesmo ano aquela em que menos ocorreram precipitações. Essa forma de agrupamento foi importante para avaliar as mudanças nas médias dos índices calculados para cada estação.

Figura 18. Somatório dos dados pluviométricos diários agrupados por estação do ano



Fonte: Autor, 2020

## 5.2 Análise dos índices biofísicos em relação à pluviometria


Analisando os gráficos das médias dos índices de vegetação, apresentados nas **figuras 19, 20, 21, 22 e 23**, observa-se que estes apresentam um mesmo padrão ilustrativo em relação à precipitação por estação.

As médias dos índices exibiram os maiores valores para o período de estudo no outono de 2014, e os menores na primavera de 2014. Os invernos de 2014 e 2015, ainda que apresentem os menores valores para o acumulado de chuva, não retornam os menores valores de média dos índices da série temporal.

Isto pode indicar algum nível de resiliência da vegetação no início do período de estiagem. Pois, nas primaveras, ainda que o acumulado de precipitação seja superior, se comparado aos invernos, as médias dos índices apresentam valores inferiores. É possível encontrar a mesma inferência nos trabalhos de (SANTOS, 2016) e (SANTOS *et al.*, 2019) onde os autores destacam que a variação apresentada no índice de vegetação estudado, diretamente relacionada ao porte e biomassa vegetal, pode estar associada às oscilações anuais de carga pluviométrica. Reforçando esse ponto, no período primaveril é possível identificar o estresse hídrico acentuado nos valores negativos de umidade na média do *NDWI Gao*, presente na **figura 23**, mostrando o esgotamento da água remanescente do período chuvoso.


Observando as diferenças das médias dos índices entre as estações em cada ciclo e as diferenças de acumulado de precipitação, é possível perceber que embora os dados pluviométricos apresentem significativas variações, elas não se refletem proporcionalmente nas médias dos índices, indicando que a medida estatística de tendência “média” para os índices estudados sob tais circunstâncias climáticas foram pouco influenciadas pela amplitude dos dados de chuva. Essa constatação permite deduzir que tal amplitude de precipitação se encontra dentro de limites mínimos para respostas biofísicas habituais da vegetação sob as condições específicas de cada estação climática. Contudo, para ratificar essa dedução é necessário aumentar o período de observação sobre a área de estudo, conferindo o comportamento vegetativo influenciado por regime de chuvas com maior diferenciação.

Figura 19. Média dos NDVI em relação à precipitação acumulada



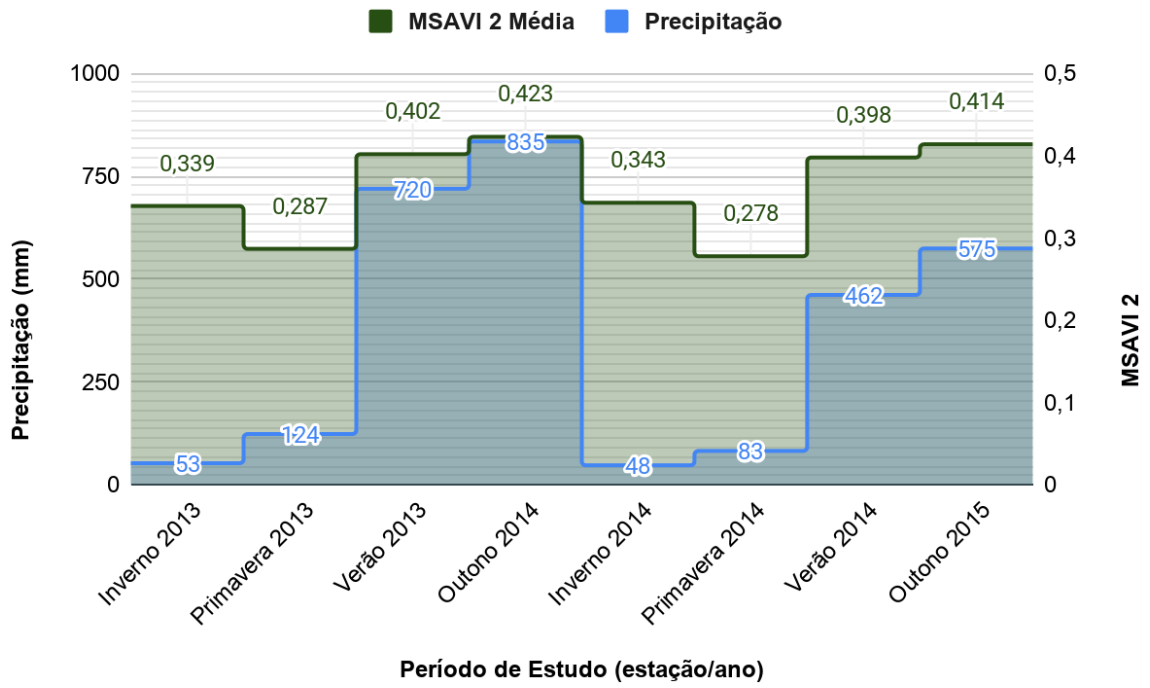
Fonte: Autor, 2020

Figura 20. Média dos EVI 2 em relação à precipitação acumulada




Fonte: Autor, 2020

Figura 21. Média dos EVI 2 em relação à precipitação acumulada




Fonte: Autor, 2020

Figura 22. Média dos LAI em relação à precipitação acumulada



Fonte: Autor, 2020

Figura 23. Média dos NDWI Gao em relação à precipitação acumulada



Fonte: Autor, 2020

Analisando a tabela e o gráfico de distribuição das classes, na **tabela 3** e na **figura 24**, nota-se que o percentual de área coberta por valores de *NDVI* para a vegetação mais vigorosa ( $> 0,7$ ) apresenta variação de cobertura de até 68% na série temporal, decrescendo em períodos secos enquanto classes que representam menor resposta de clorofila ( $0,3 < NDVI < 0,6$ ) apresentam crescimento significativo. A cobertura para as classes de valores mais baixos permanecem estáveis e pouco expressivas ao longo de todo o período, reafirmando a ideia de resiliência da vegetação.

Resultado próximo ocorre no trabalho de Gamiero *et al.* (2017), onde a vegetação densa chegou a 60% de área em período úmido e 11% no período seco para a bacia do baixo Jaguaribe - CE. Um comportamento similar foi encontrado por Boratto e Gomide (2013), em pesquisa realizada em Gortuba, norte de Minas Gerais, que ainda afirma que no período seco, um valor de *NDVI* muito próximo à zero, caracteriza uma área com os solos expostos, vegetação seca ou com pouca vegetação (rala ou menos densa).

Santos *et al.* (2016) encontrou resultados *NDVI* para as classes mais altas no PNSC respectivamente equivalentes a 72,2%, 51,9% e 85% da área para os anos de 1998, 2006 e 2014.

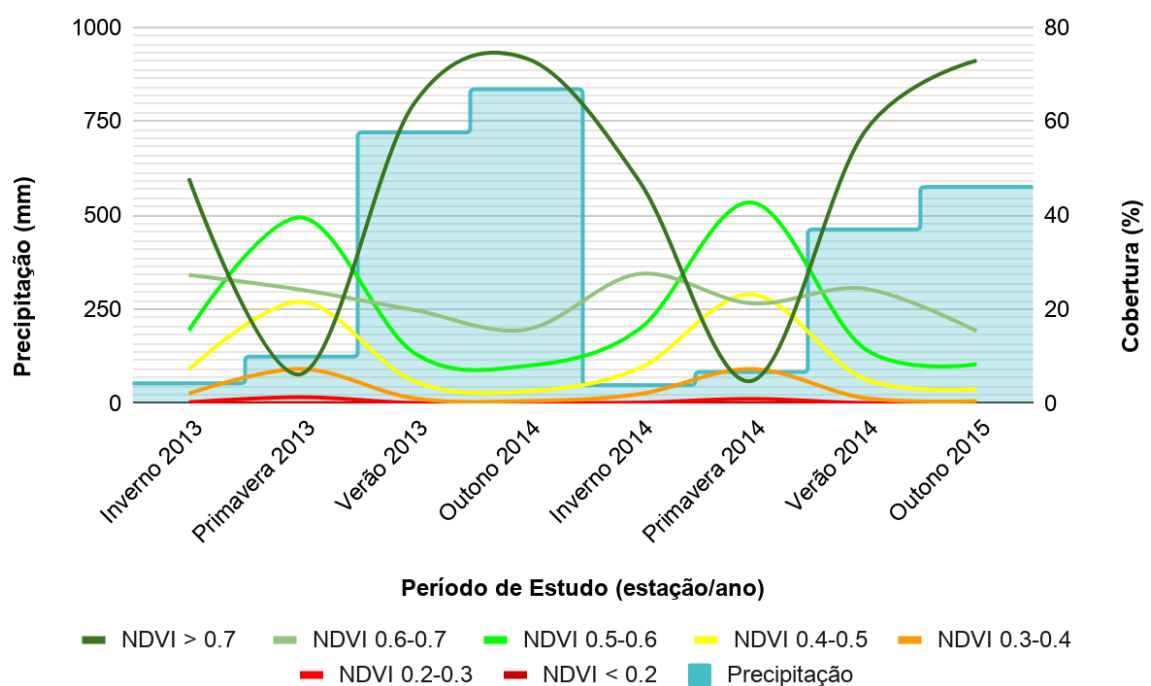
Tabela 3. Distribuição percentual de cobertura das classes NDVI

Estação / Classe	Inverno 2013	Primavera 2013	Verão 2013	Outono 2014	Inverno 2014	Primavera 2014	Verão 2014	Outono 2015
<i>NDVI</i> < 0,2	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00
<i>NDVI</i> 0,2-0,3	0,20	1,28	0,04	0,01	0,12	0,91	0,04	0,01
<i>NDVI</i> 0,3-0,4	2,05	7,29	1,06	0,48	1,93	7,29	1,13	0,45
<i>NDVI</i> 0,4-0,5	7,15	21,57	4,65	2,54	7,40	23,13	5,20	3,02
<i>NDVI</i> 0,5-0,6	15,47	39,51	10,72	7,94	15,69	42,70	11,67	8,29
<i>NDVI</i> 0,6-0,7	27,29	24,13	19,84	15,68	27,51	21,25	24,39	15,34
<i>NDVI</i> > 0,7	47,85	6,21	63,70	73,35	47,34	4,72	57,57	72,89

Fonte: Autor, 2020

A sensibilidade da vegetação à variação pluviométrica ocorrida entre as estações chuvosas dos dois ciclos se mostra pouco significativa, porém existente. Tal sensibilidade é notada de melhor forma observando o período de estiagem. Na primavera de 2014 a vegetação mais vigorosa sofreu impacto relativamente maior em relação à mesma estação em 2013, dada a maior escassez de chuvas apresentadas no ciclo estacionário 2014/2015.

Figura 24. Cobertura percentual das classes dos NDVI e precipitação acumulada em relação às estações



Fonte: Autor, 2020



Observando o mapeamento do *NDVI* nas **figuras 25 e 26**, é possível notar que há partes a leste e a oeste que permanecem sob a mesma classe ao longo das estações, indicando uma vegetação esparsa, rasteira, de pouca folhagem ou baixos níveis de clorofila. Quanto à vegetação mais proeminente nota-se a sinuosidade de seu traçado na primavera, indicando tratar-se de mata de galeria, explicando seus níveis de *NDVI* na estação seca.

Entre os ciclos é possível perceber uma maior intensidade das classes de menor valor de *NDVI* na primavera de 2014 em relação à de 2013, reafirmando as análises anteriores. O verão e o inverno de 2014 apresentam menor expressividade do verde mais forte nitidamente se comparados aos de 2013, denotando a influência da precipitação. Contudo, o outono de 2015 não demonstra visualmente concordância com essa influência como nos dados tabelados quando comparado a 2014.

Figura 25. Parque Nacional de Sete Cidades - NDVI do primeiro ciclo estacionário 2013/2014

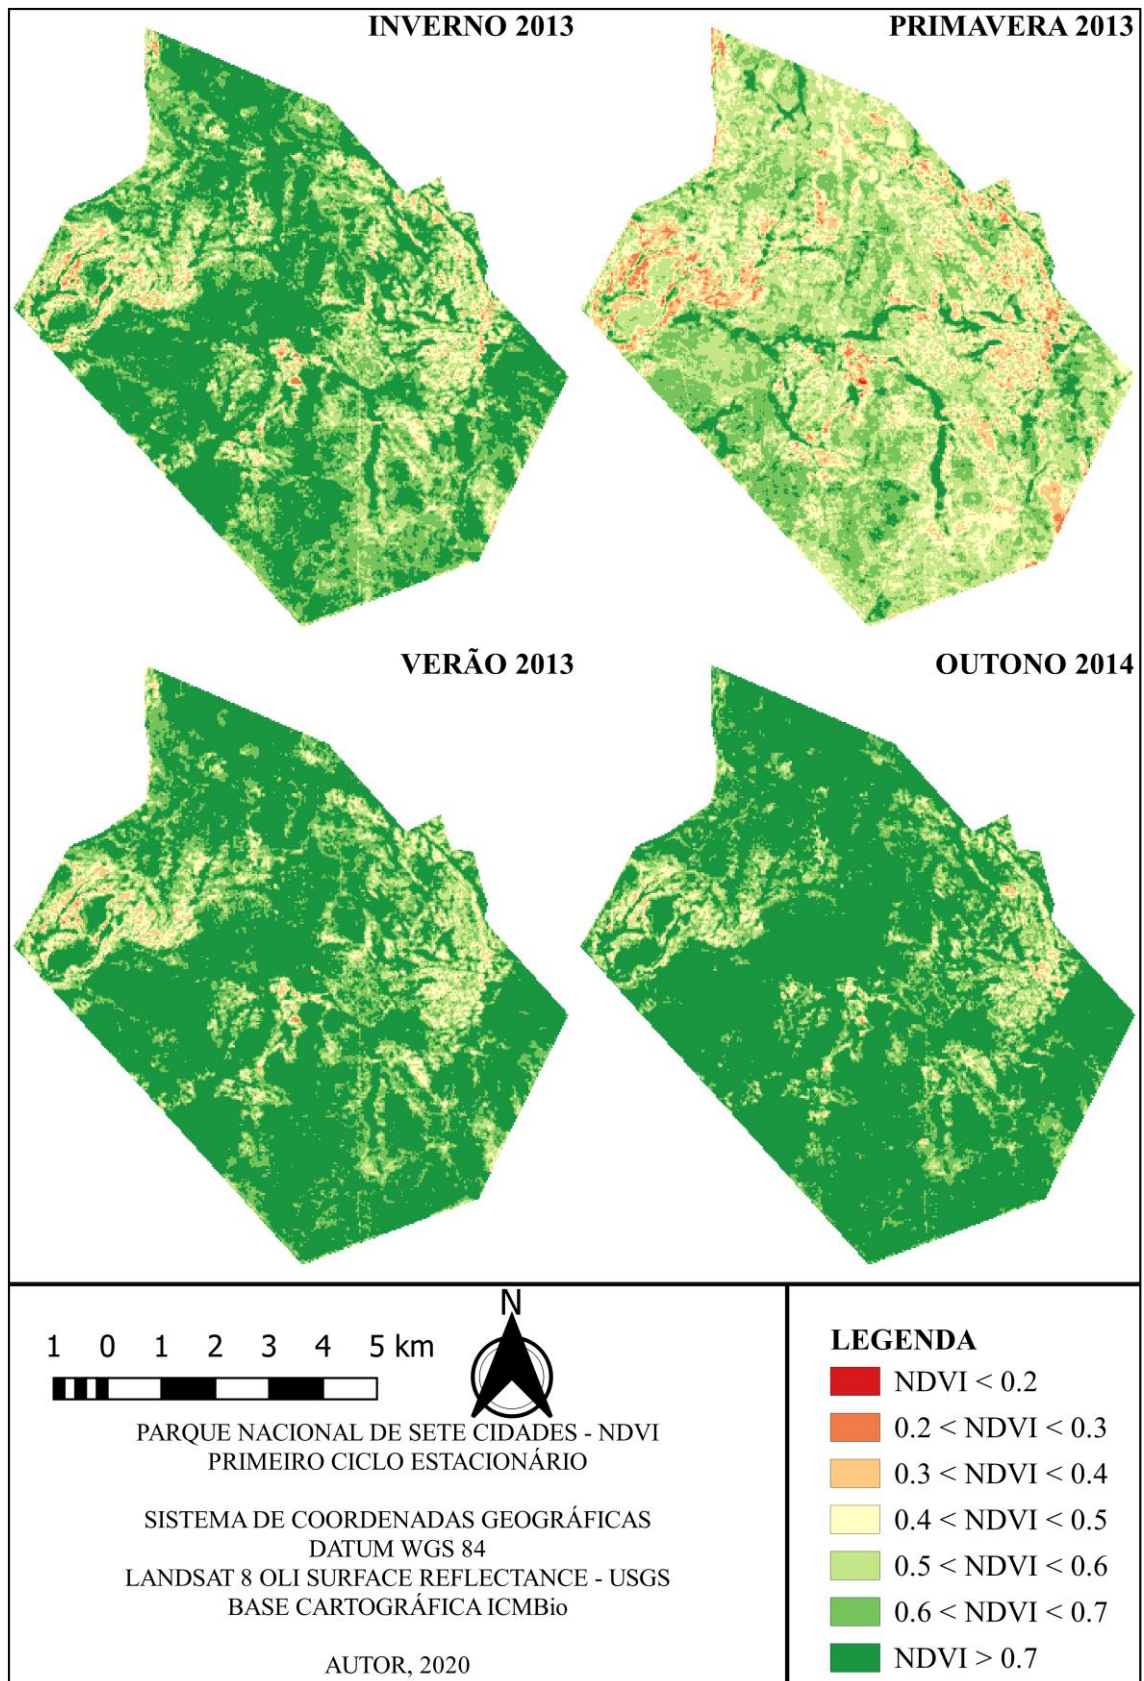
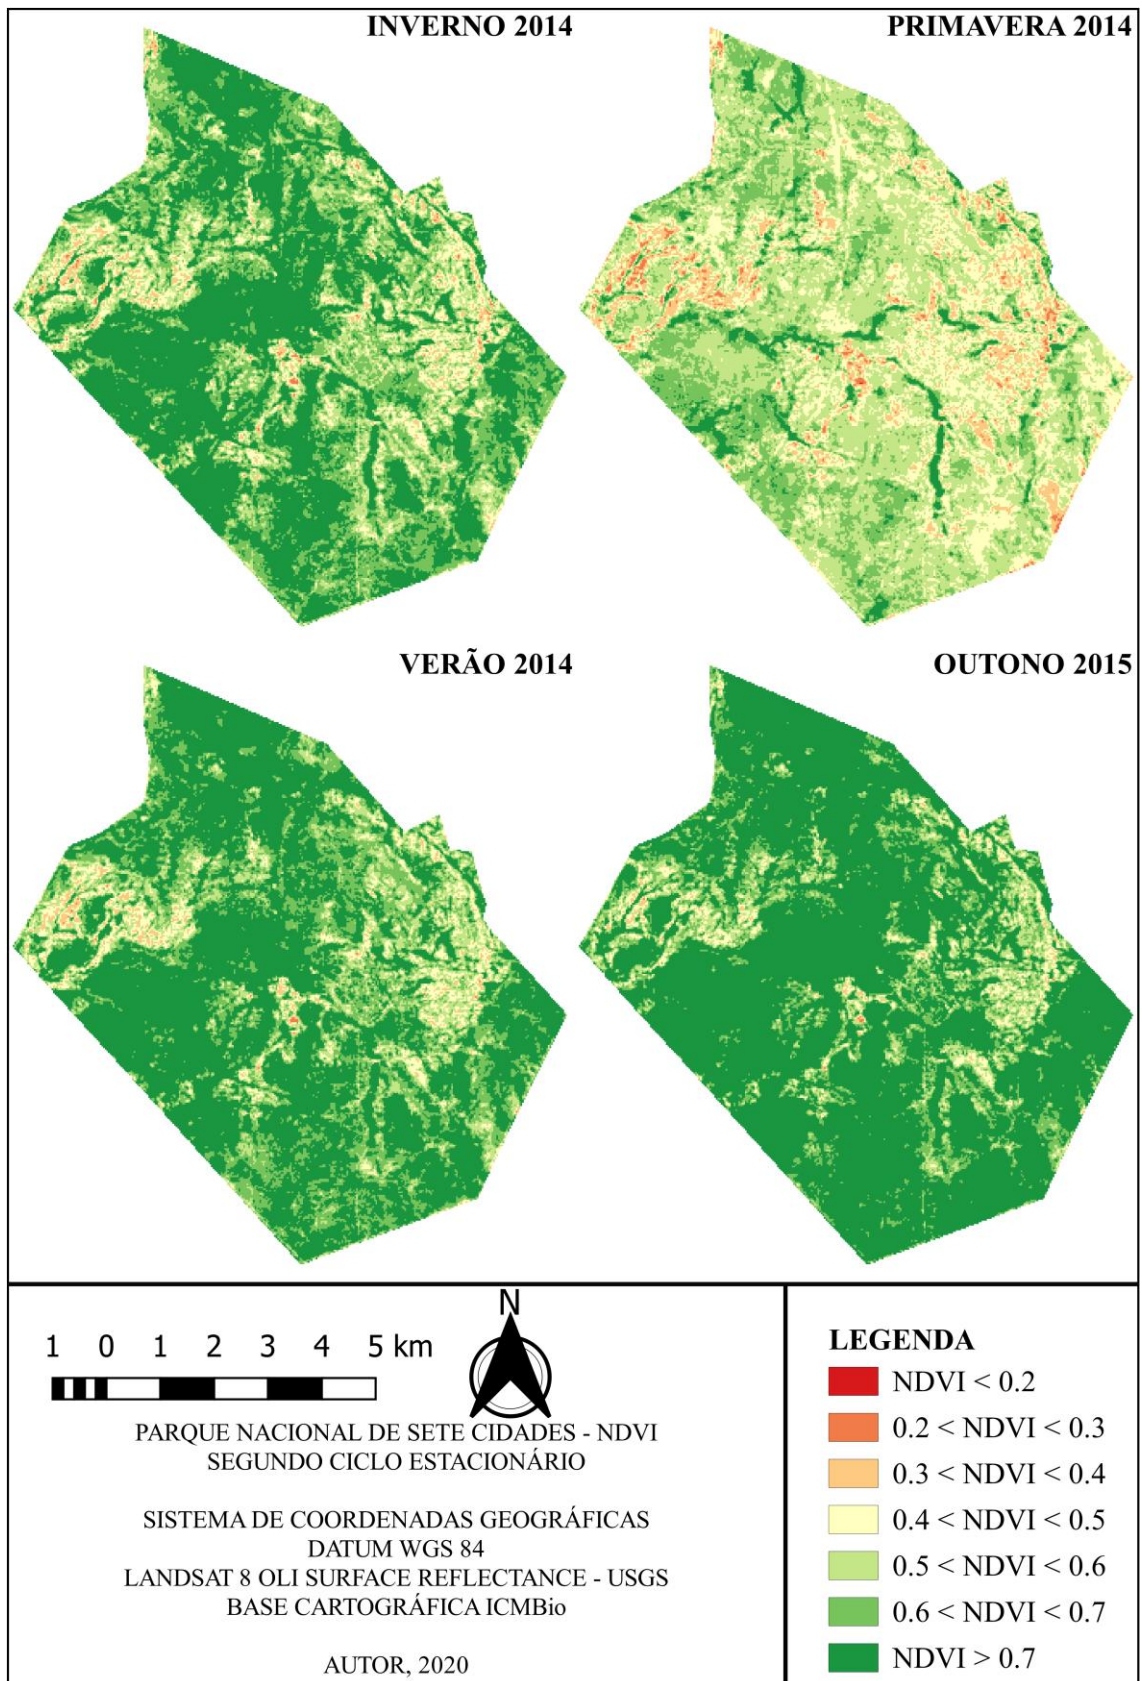


Figura 26. Parque Nacional de Sete Cidades - NDVI do segundo ciclo estacionário 2014/2015



Passando a análise aos resultados de distribuição de classes do índice *EVI 2*, presentes na **tabela 4** e **figura 27**, evidencia-se que o índice apresentou menor amplitude entre as classes quando comparado ao *NDVI*, não apresentando classes com cobertura maior que 50% do terreno. Esse fenômeno se explica pela característica do índice de melhorar a diferenciação entre estruturas vegetais em relação a melhor identificação de clorofila obtida pelo *NDVI*.

O *EVI 2* aprimora os resultados do *EVI* padrão, que por sua vez aprimora os resultados do *NDVI*, para analisar a vegetação com menor influencia do solo e ruído dos efeitos atmosféricos. O artigo de De Paula *et al.* (2013) afirma que os resultados do *EVI 2* se correlacionam aos do *EVI*, viabilizando comparações com trabalhos que utilizaram este último índice nas análises ambientais.

Como ocorrido com o *NDVI* a cobertura dos maiores valores de *EVI 2* ( $> 0,45$ ) foram encontrados em abundância nos períodos mais chuvosos sendo de menor ocorrência no período mais seco. Demonstrando sensibilidade hídrica e constituição resiliente da vegetação. Pelo *EVI 2* constata-se que no período de estiagem há uma perda maior de biomassa do que a evidenciada no *NDVI*, imprimindo valores mais relacionáveis às quantidades de precipitação mensuradas.

Tabela 4. Distribuição percentual de cobertura das classes *EVI 2*

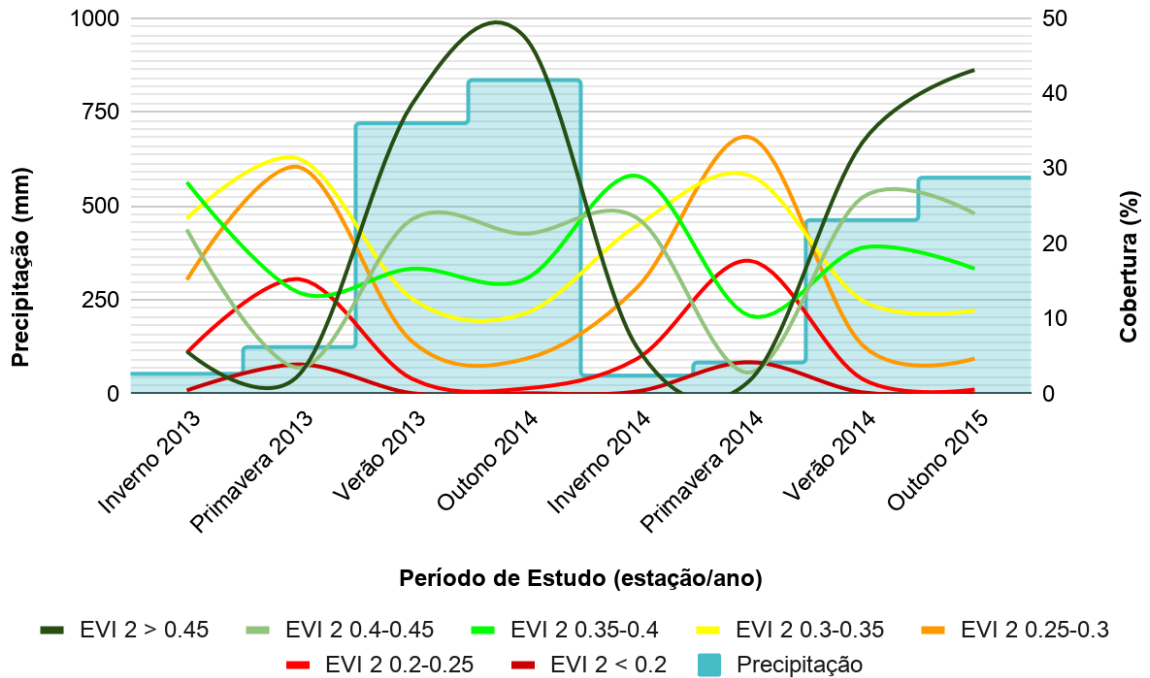
Estação / Classe	Inverno 2013	Primavera 2013	Verão 2013	Outono 2014	Inverno 2014	Primavera 2014	Verão 2014	Outono 2015
<i>EVI 2</i> < 0.2	0,43	3,90	0,06	0,05	0,30	4,19	0,18	0,03
<i>EVI 2</i> 0.2-0.25	5,46	15,24	1,98	0,68	4,64	17,69	1,98	0,56
<i>EVI 2</i> 0.25-0.3	15,15	30,14	6,95	4,60	14,12	34,14	6,51	4,68
<i>EVI 2</i> 0.3-0.35	23,33	31,26	12,66	10,65	22,39	29,05	12,42	11,06
<i>EVI 2</i> 0.35-0.4	28,16	13,43	16,63	15,22	28,99	10,37	19,43	16,63
<i>EVI 2</i> 0.4-0.45	21,85	3,47	23,21	21,29	23,39	2,83	26,09	23,96
<i>EVI 2</i> > 0.45	5,63	2,56	38,51	47,51	6,17	1,73	33,39	43,09

Fonte: Autor, 2020

Pelo gráfico da **figura 27**, pode-se constatar que a vegetação de classificação mais intermediária prevalece ao longo das estações, denotando boa conservação da biomassa do Parque mesmo em escassez hídrica. Observando o mapeamento nas **figuras 28** e **29**, nota-se maior diferenciação entre as estações secas e chuvosas, melhor delineamento da mata de

galeria nas estações secas e constatação visual mais coerente aos dados tabulados quando comparado ao *NDVI*. O segundo ciclo de estações salienta a resposta da vegetação à níveis de chuva menores que os ocorridos no primeiro ciclo do período de estudo.

Figura 27. Cobertura percentual do *EVI 2* e precipitação acumulada em relação às estações



Fonte: Autor, 2020

Diferentemente do estudo de Billar *et al.* (2018) para o Parque Estadual da Mata da Pimenteira (PEMP), o qual estudou o índice *EVI* ao invés do *EVI 2* utilizado nesse estudo, na estação seca valores maiores de *EVI 2* > 0,30 aparecem em mais de 30% do território do PNSC.

Figura 28. Parque Nacional de Sete Cidades – EVI 2 do primeiro ciclo estacionário 2013/2014

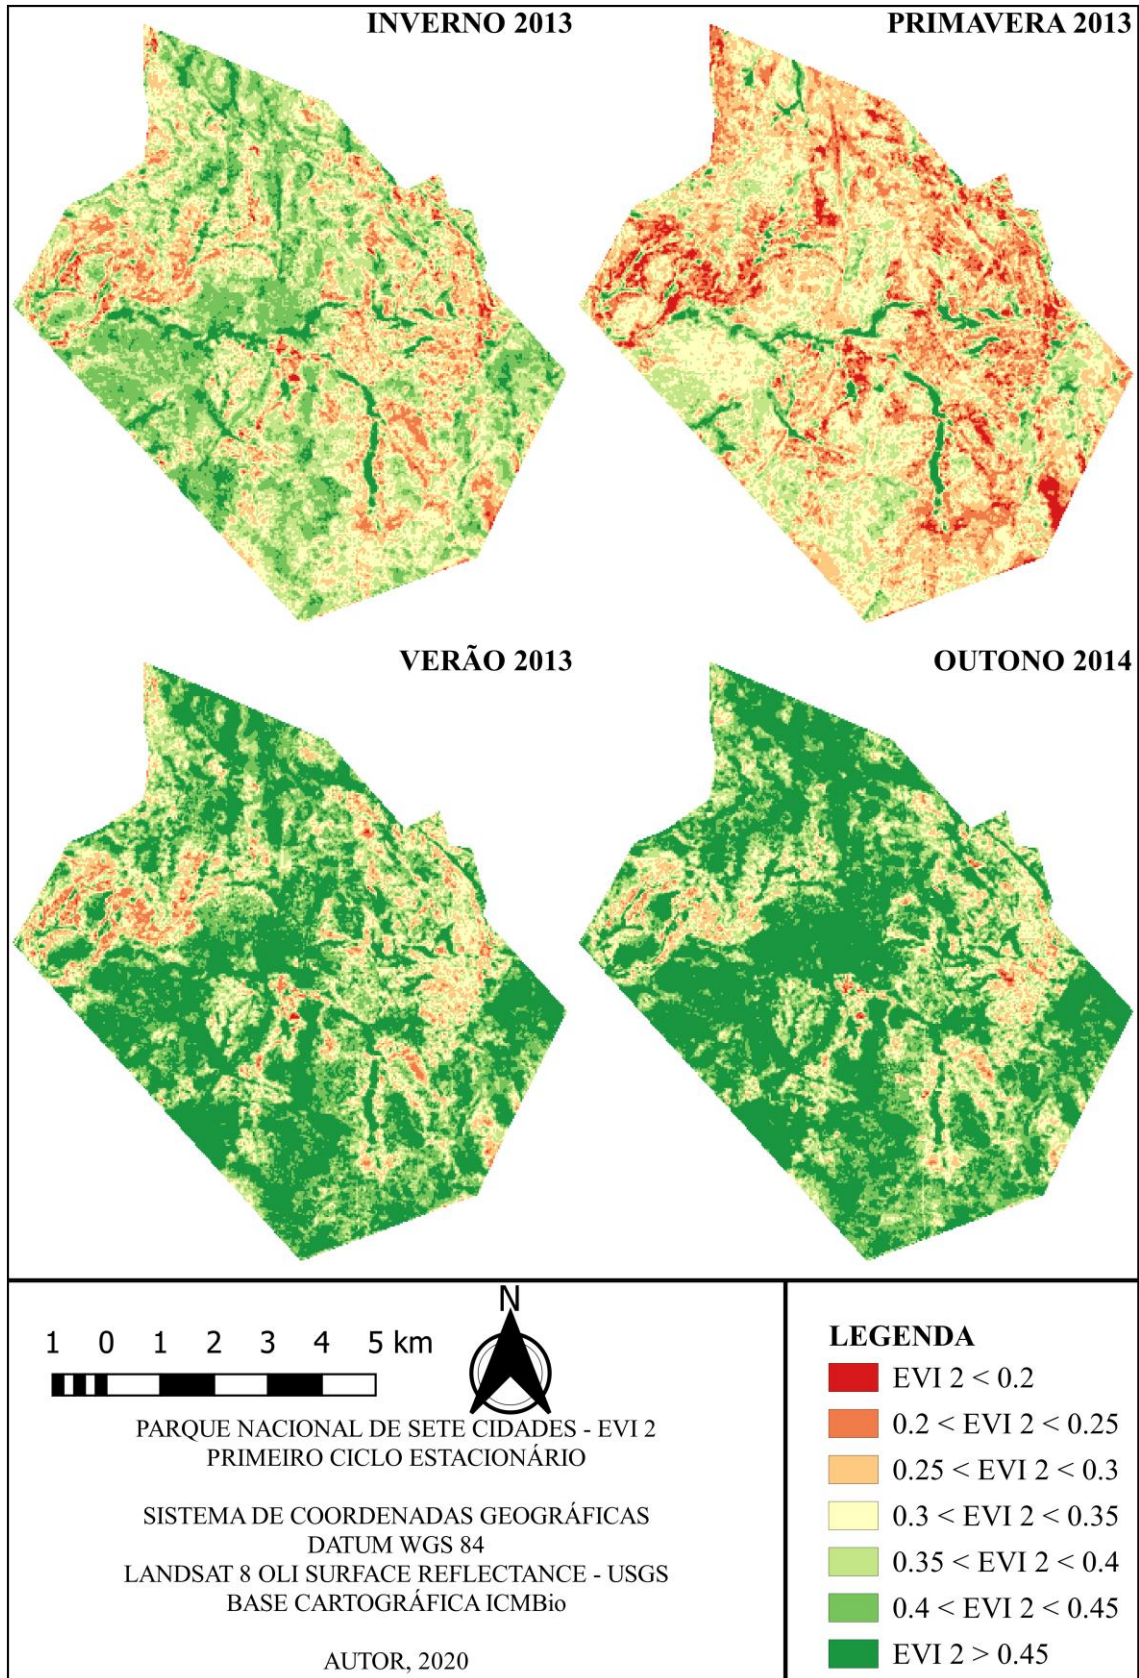
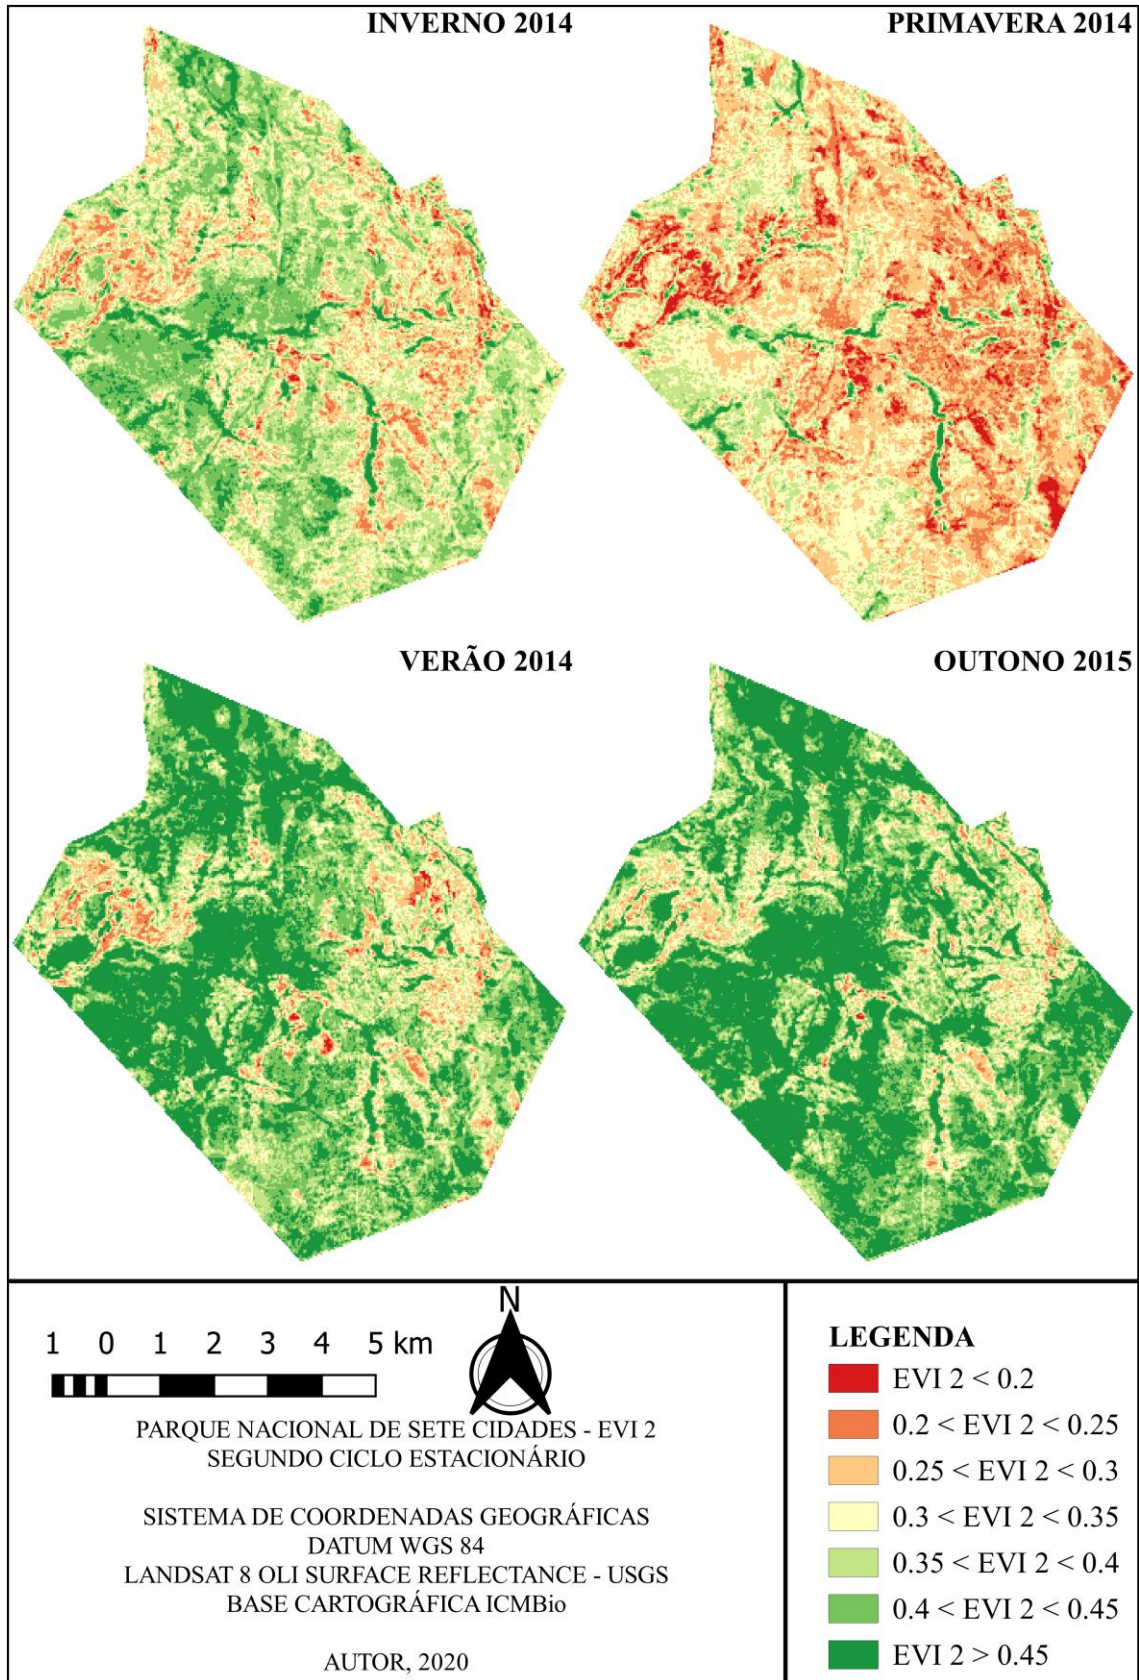


Figura 29. Parque Nacional de Sete Cidades – EVI 2 do segundo ciclo estacionário 2014/2015



Com relação ao índice *MSAVI 2*, observando a **tabela 5, figuras 30, 31 e 32**, esse tem por característica reduzir o *background* do solo de forma autocompensativa (diferentemente do *SAVI* padrão), os resultados mostram que os valores do índice se concentram quase em equilíbrio na classe ( $0,3 < MSAVI 2 < 0,4$ ) durante a maior parte do período de estudo.

Quando nas estações de maior precipitação a classe ( $0,4 < MSAVI 2 < 0,5$ ) apresenta quase 50% de ocupação no parque. O intervalo de valores ( $0,2 < MSAVI 2 < 0,3$ ) é o que apresenta maiores percentuais de ocupação na primavera, a mais seca, denotando que essa distribuição de classes não é a mais adequada, porém é suficiente para o entendimento da dinâmica vegetal.

No estudo sobre o PEMP, de Billar *et al.* (2018), os resultados de cobertura se apresentaram semelhantes aos do corrente estudo para o período seco, pois valores de *SAVI* > 0,30 ocuparam mais de 45% da área de estudo. Já a pesquisa de De França e Silva, da Silva e Alves (2017) demonstra a predominância de valores de *SAVI* entre 0,2 – 0,4 no período seco e 0,4 – 0,6 no período chuvoso, resultado que se aproxima do encontrado no corrente estudo, uma vez que *SAVI* e *MSAVI 2* são índices relacionados, mas não idênticos, e a área pesquisa pelo autores previamente citados tem características puramente do bioma caatinga, enquanto o PNSC se denota como uma zona de transição entre biomas.

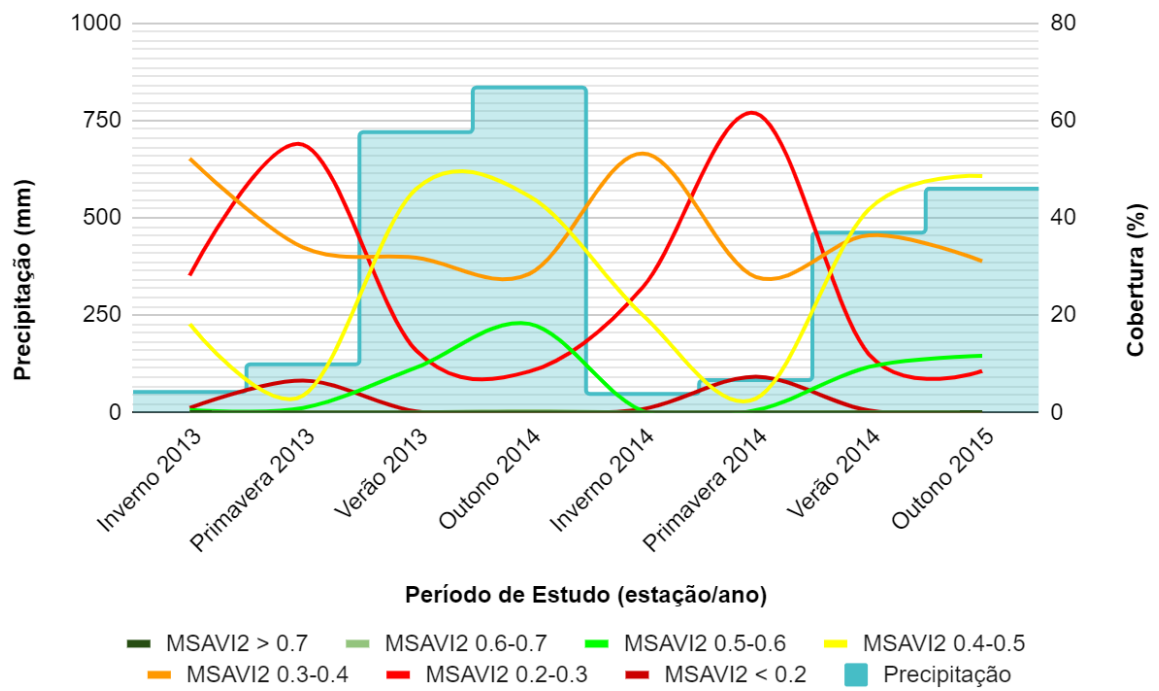
Tabela 5. Distribuição percentual de cobertura das classes *MSAVI 2*

Estação / Classe	Inverno 2013	Primavera 2013	Verão 2013	Outono 2014	Inverno 2014	Primavera 2014	Verão 2014	Outono 2015
<i>MSAVI 2</i> < 0.2	0,93	6,58	0,23	0,13	0,70	7,34	0,41	0,05
<i>MSAVI 2</i> 0.2-0.3	28,15	55,05	12,76	8,43	25,68	61,48	11,94	8,52
<i>MSAVI 2</i> 0.3-0.4	52,18	33,94	31,81	28,50	53,24	27,84	36,43	31,11
<i>MSAVI 2</i> 0.4-0.5	18,21	3,46	45,93	44,44	20,05	2,85	41,78	48,59
<i>MSAVI 2</i> 0.5-0.6	0,53	0,93	9,23	18,22	0,32	0,47	9,38	11,66
<i>MSAVI 2</i> 0.6-0.7	0,00	0,04	0,05	0,28	0,00	0,02	0,07	0,07
<i>MSAVI 2</i> > 0.7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Fonte: Autor, 2020



Figura 30. Cobertura percentual do MSAVI 2 e precipitação acumulada em relação às estações



Fonte: Autor, 2020

Figura 31. Parque Nacional de Sete Cidades – MSAVI 2 do primeiro ciclo estacionário 2013/2014

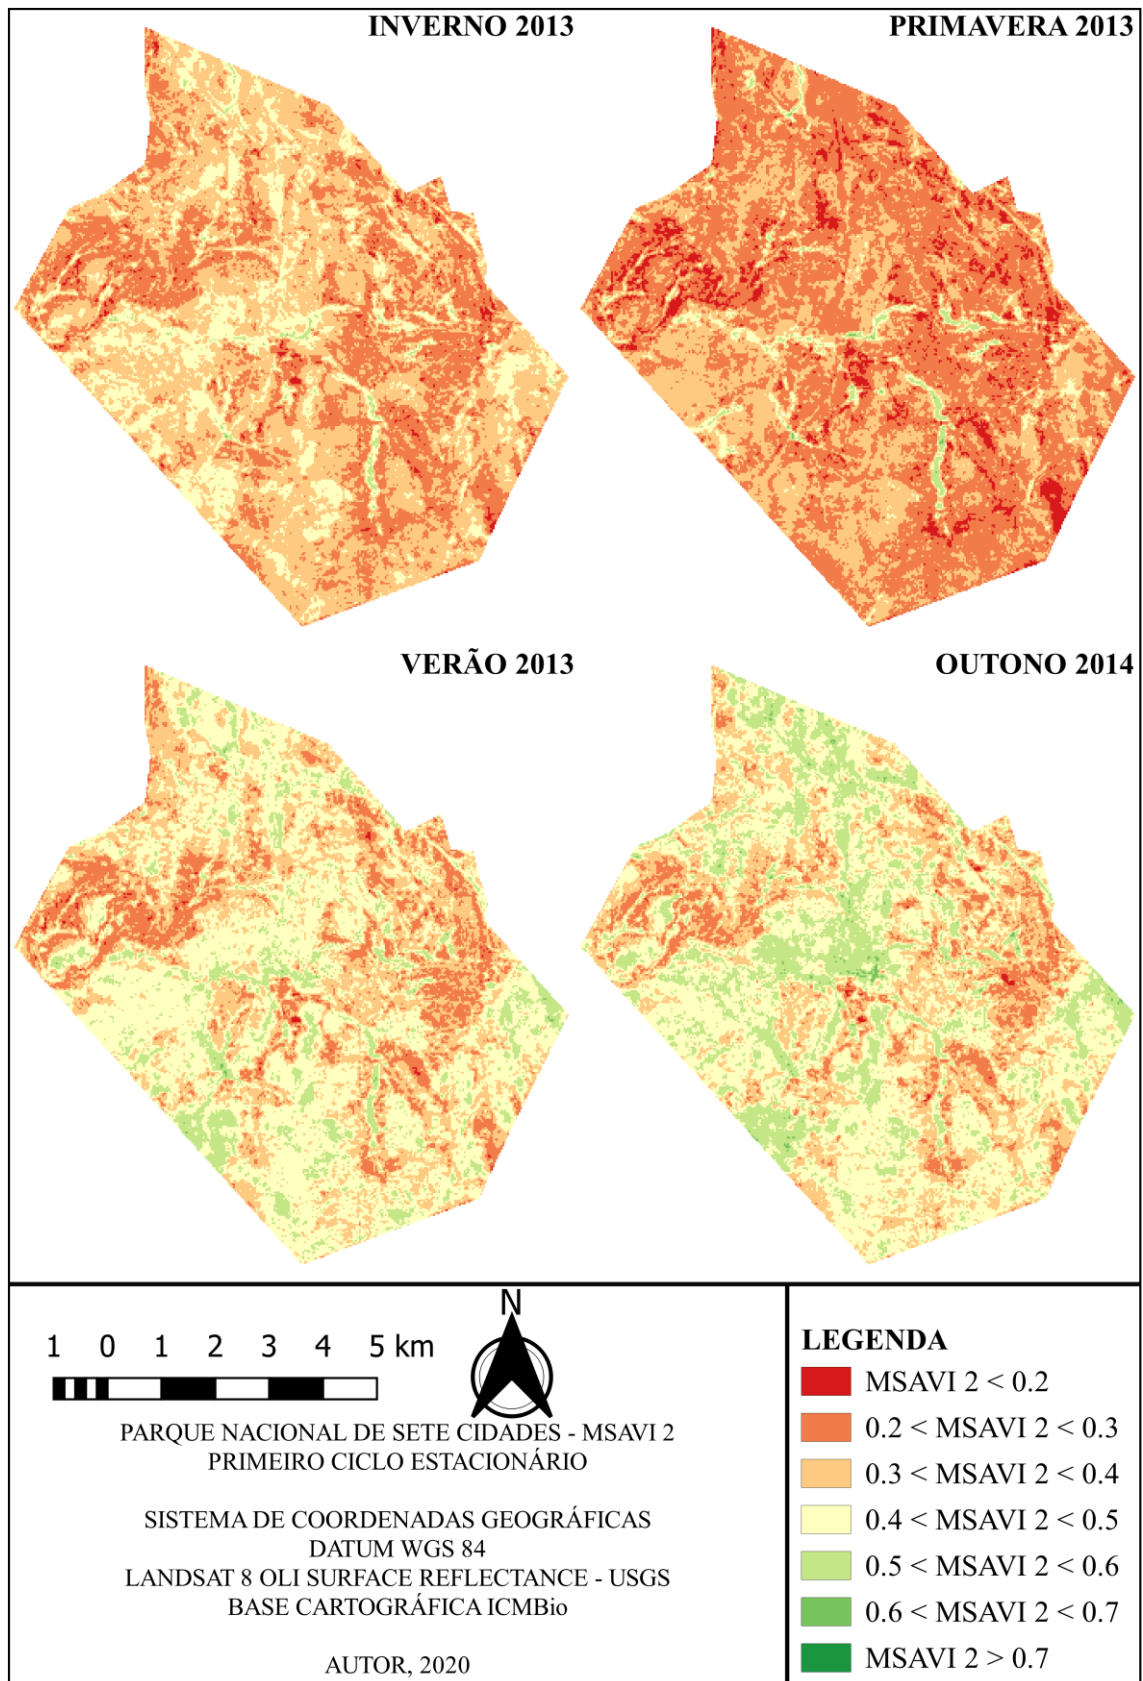
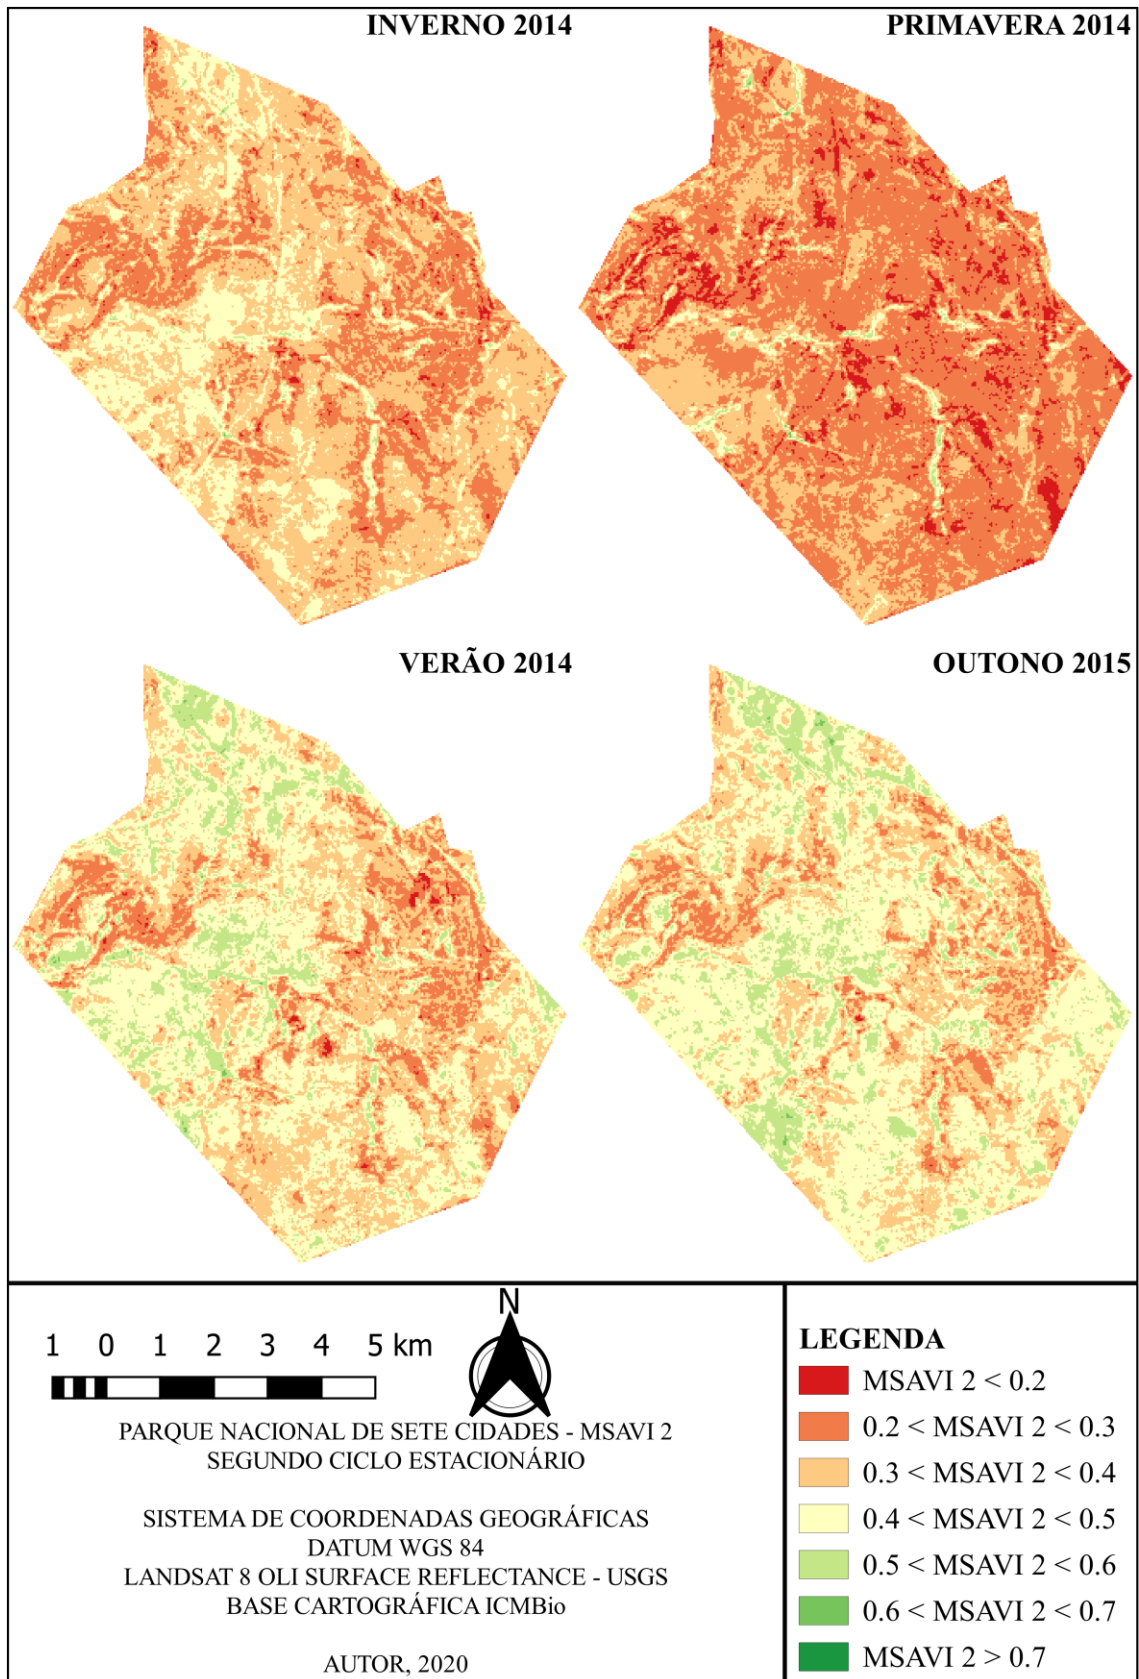


Figura 32. Parque Nacional de Sete Cidades – MSAVI 2 do segundo ciclo estacionário 2014/2015



No que diz respeito ao índice de umidade presente na vegetação (*NDWI Gao*) os valores muito negativos (classes com *NDWI Gao* < -0,15) são encontrados no período de inverno a verão (**tabela 6 e figura 33**). Observando o mapeamento (**figuras 34 e 35**) nota-se que se concentram sobre uma mesma região, onde ocorre afloramento rochoso. A redução quase total desta classe no outono pode indicar um maior desenvolvimento do “cerrado extremamente xeromórfico” durante esse período, o qual é destacado por Oliveira (2007) por se instalar sobre a rocha.

Na primavera a vegetação se mostra majoritariamente seca (*NDWI Gao* < 0 em mais 69% do terreno). No outono é observável que há concentração de áreas sob a classe de maior umidade (*NDWI Gao* > 0,3), podendo tratar-se de planícies inundáveis.

A mata de galeria destacada nos índices anteriores se mostra recorrente sob a ótica do *NDWI Gao*, denotando seu contato contínuo com a água. A classe ( $0 < NDWI Gao < 0,15$ ) se mostra significativamente expressiva ao longo de todas as estações, reafirmando a resiliência da vegetação durante a estiagem. O segundo ciclo estacionário apresentou menores valores de umidade se comparado ao primeiro, explicando-se pela redução de chuvas.

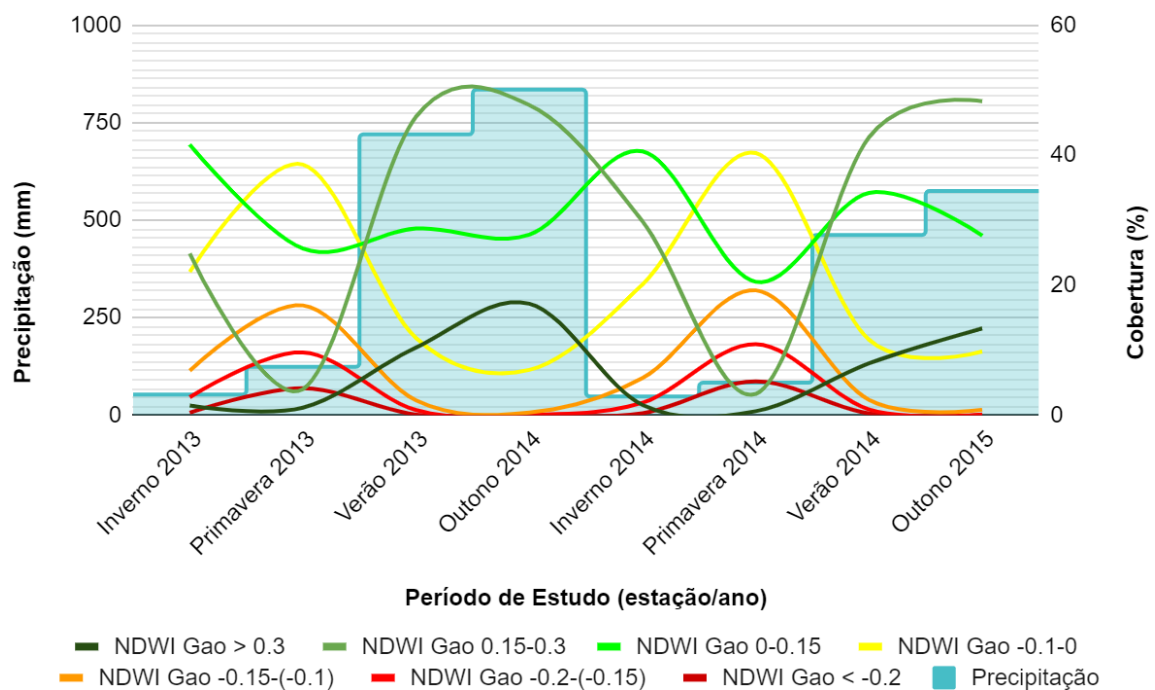
Em Billar *et al.* (2018), valores muito positivos de *NDWI* (acima de 0,32) representam corpos de água, porém, para no PNSC não há observação de corpos d’água superficiais, por isso estes valores podem significar solos saturados neste caso.

Tabela 6. Distribuição percentual de cobertura das classes *NDWI Gao*

Estação / Classe	Inverno 2013	Primavera 2013	Verão 2013	Outono 2014	Inverno 2014	Primavera 2014	Verão 2014	Outono 2015
NDWI Gao < -0.2	0,37	4,14	0,08	0,00	0,29	5,19	0,24	0,00
NDWI Gao -0.2-(-0.15)	2,76	9,66	0,76	0,03	1,91	10,92	0,88	0,11
NDWI Gao -0.15-(-0.1)	6,84	16,88	2,26	0,38	5,71	19,20	2,35	0,82
NDWI Gao -0.1-0	22,04	38,56	11,84	6,96	20,13	40,33	11,60	9,80
NDWI Gao 0-0.15	41,63	25,63	28,72	27,77	40,59	20,51	34,20	27,63
NDWI Gao 0.15-0.3	24,87	4,00	45,93	47,71	29,81	3,26	42,77	48,29
NDWI Gao > 0.3	1,48	1,13	10,41	17,14	1,56	0,60	7,96	13,35

Fonte: Autor, 2020

Figura 33. Cobertura percentual do NDWI Gao e precipitação acumulada em relação às estações



Fonte: Autor, 2020

Figura 34. Parque Nacional de Sete Cidades – NDWI Gao do primeiro ciclo estacionário 2013/2014

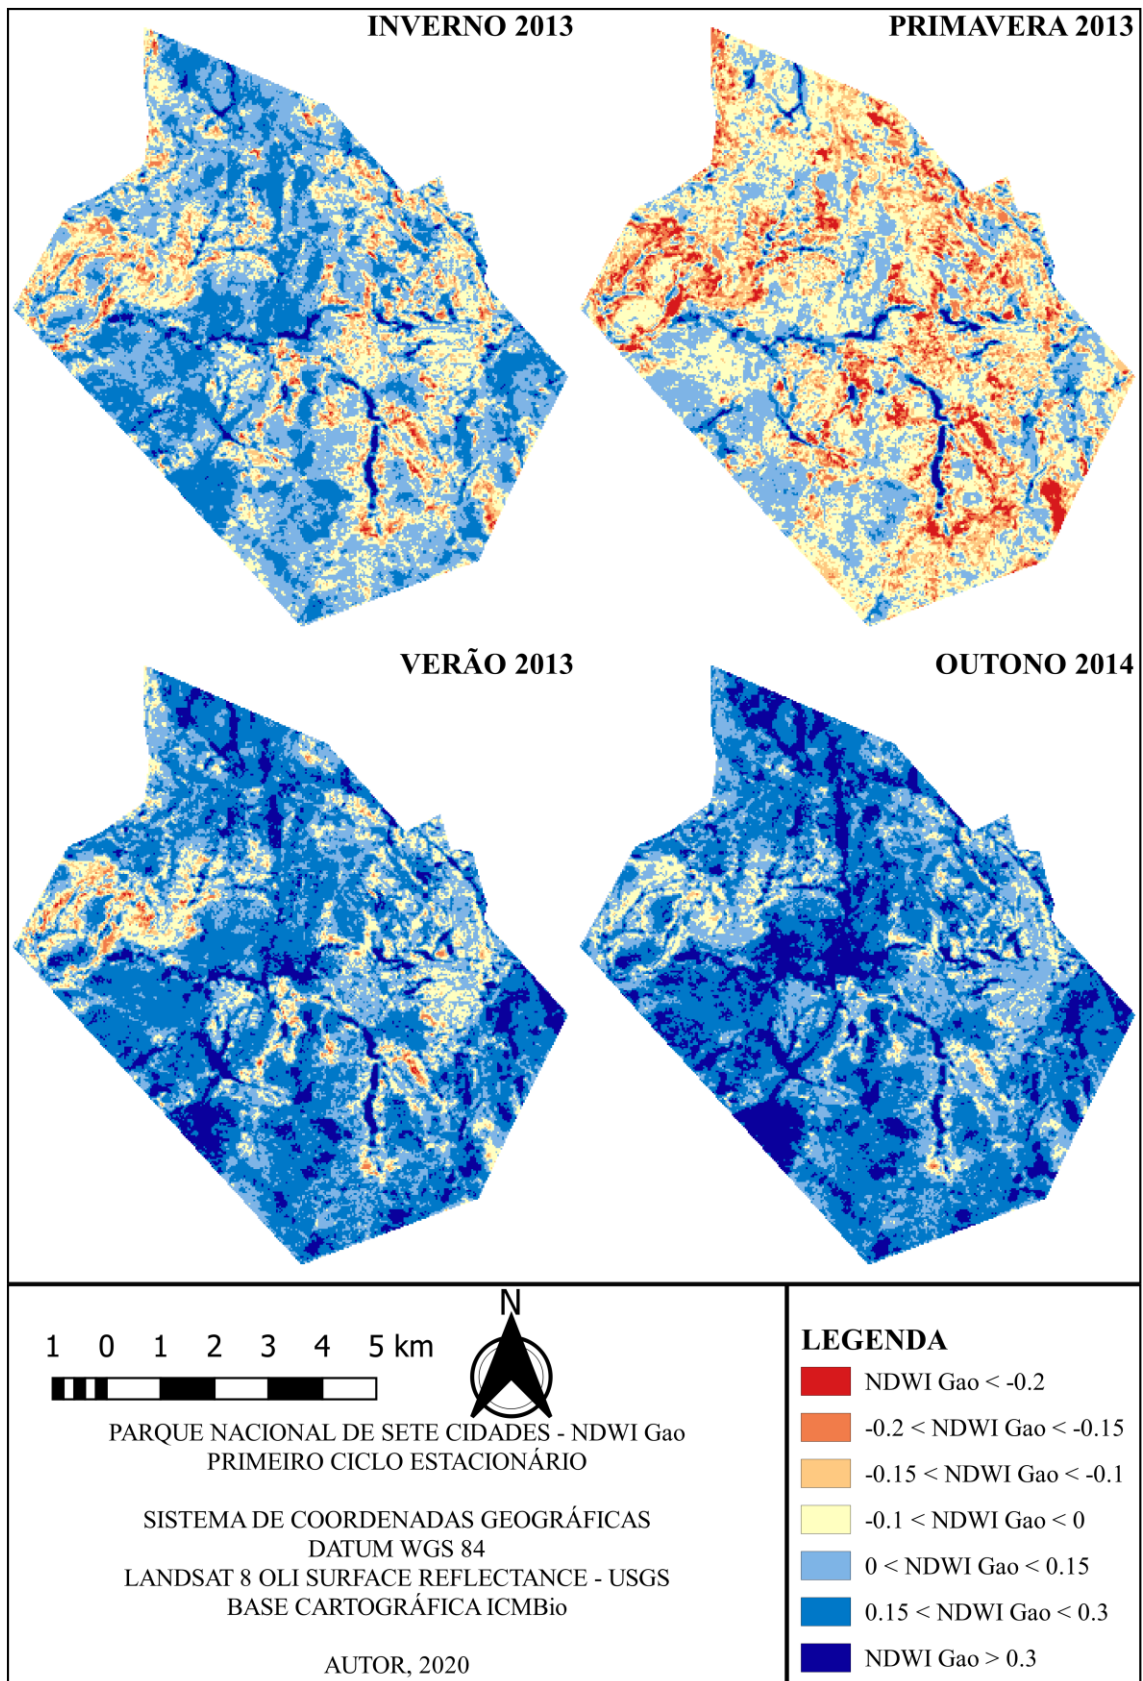
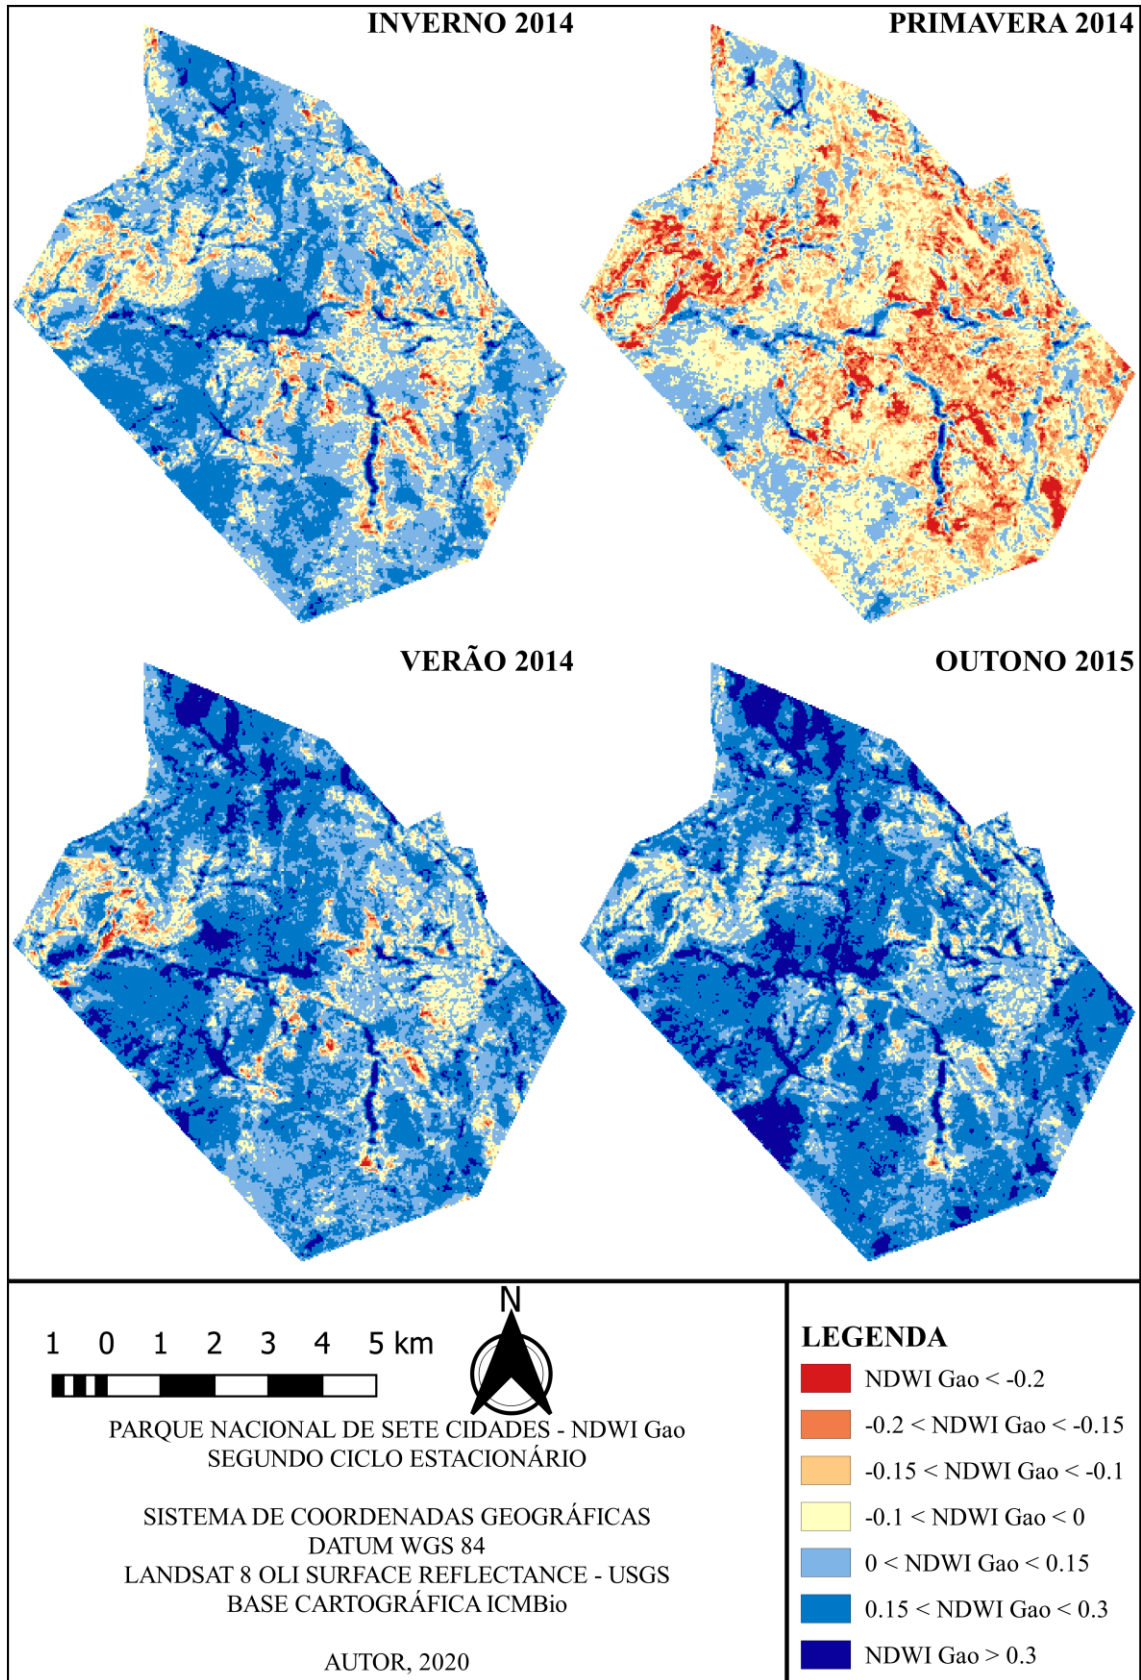


Figura 35. Parque Nacional de Sete Cidades – NDWI Gao do segundo ciclo estacionário 2014/2015



O índice que estima a área foliada, *LAI*, é baseado no índice *MSAVI 2*, e acompanha os resultados obtidos em sua origem, apresentando crescimento das classes de menor valor com a menor ocorrência de chuvas. Logo, entende-se que a vegetação demonstra grande perda de folhagem na época seca, revitalizando-se com a vinda das chuvas.

As regiões mais ao centro, norte e sudoeste apresentam maiores valores ao longo do período estudado. Não há ocorrência de valores negativos, o que significa não apresentar áreas desertificadas ou artificiais significativas a resolução espacial das imagens. Comparando-se os dois ciclos de estações, nota-se a diferenciação entre relativa à variação na precipitação e a reincidência da classe ( $0 < LAI < 0,5$ ) sobre áreas de afloramento rochoso.

Em Boratto e Gomide (2013), encontrou os maiores valores de *LAI* para áreas irrigadas, seguindo este conceito nota-se que a mata de galeria acompanha o mesmo desempenho nessa pesquisa.

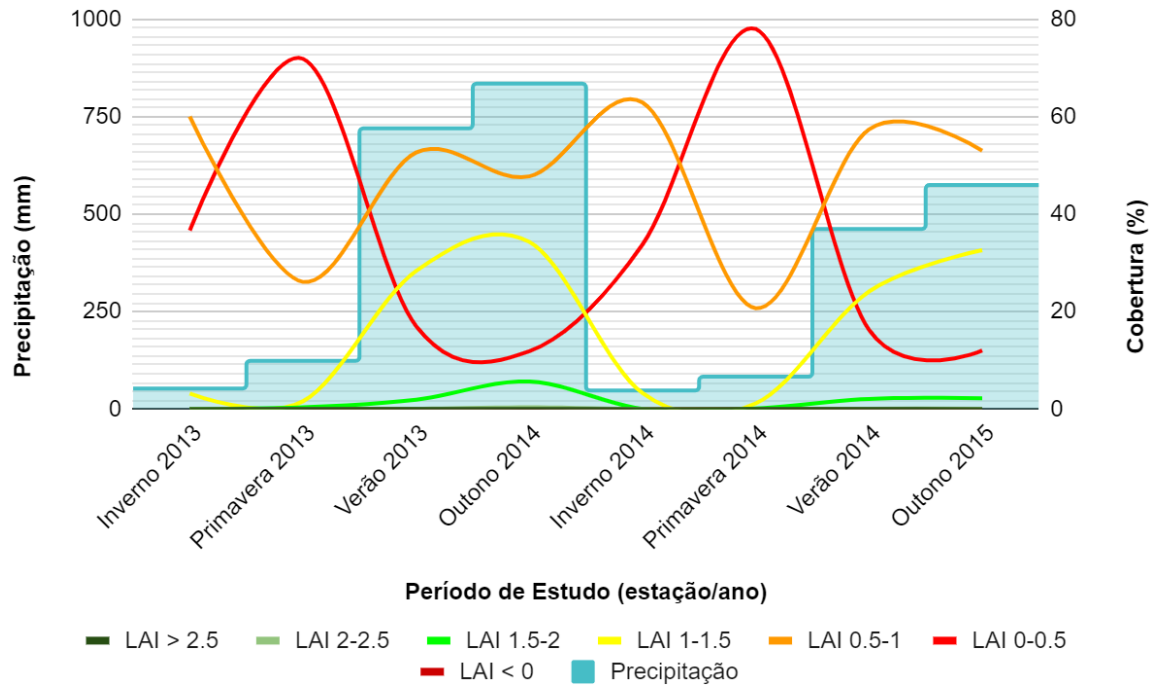
Tabela 7. Distribuição percentual de cobertura das classes *LAI*

Estação / Classe	Inverno 2013	Primavera 2013	Verão 2013	Outono 2014	Inverno 2014	Primavera 2014	Verão 2014	Outono 2015
LAI < 0	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
LAI 0-0.5	36,68	71,89	17,02	11,89	33,79	77,98	16,27	12,03
LAI 0.5-1	60,05	26,10	52,64	47,76	62,90	20,70	57,41	53,01
LAI 1-1.5	3,20	1,60	28,35	34,29	3,27	1,17	24,12	32,62
LAI 1.5-2	0,07	0,36	1,92	5,66	0,03	0,12	2,10	2,24
LAI 2-2.5	0,00	0,04	0,07	0,37	0,01	0,00	0,10	0,09
LAI > 2.5	0,00	0,01	0,01	0,03	0,00	0,01	0,00	0,00

Fonte: Autor, 2020



Figura 36. Cobertura percentual do LAI e precipitação acumulada em relação às estações



Fonte: Autor, 2020

Figura 37. Parque Nacional de Sete Cidades – LAI do primeiro ciclo estacionário 2013/2014

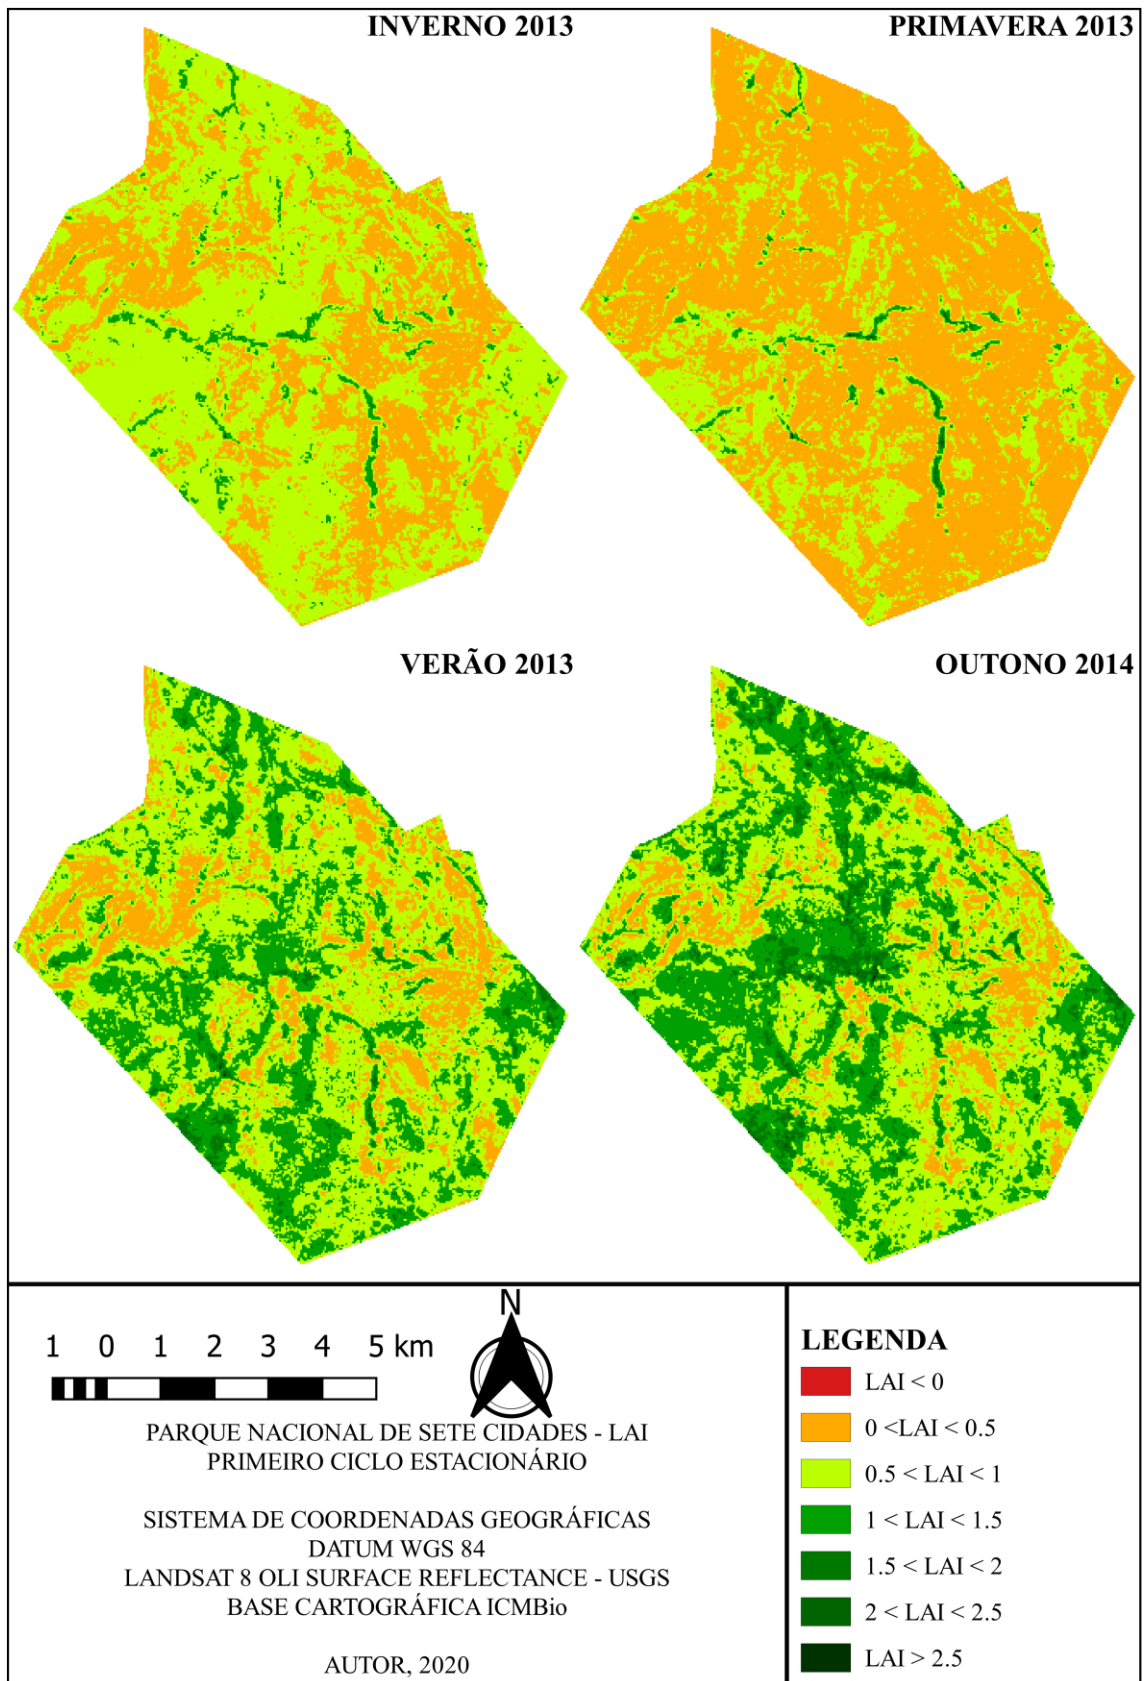
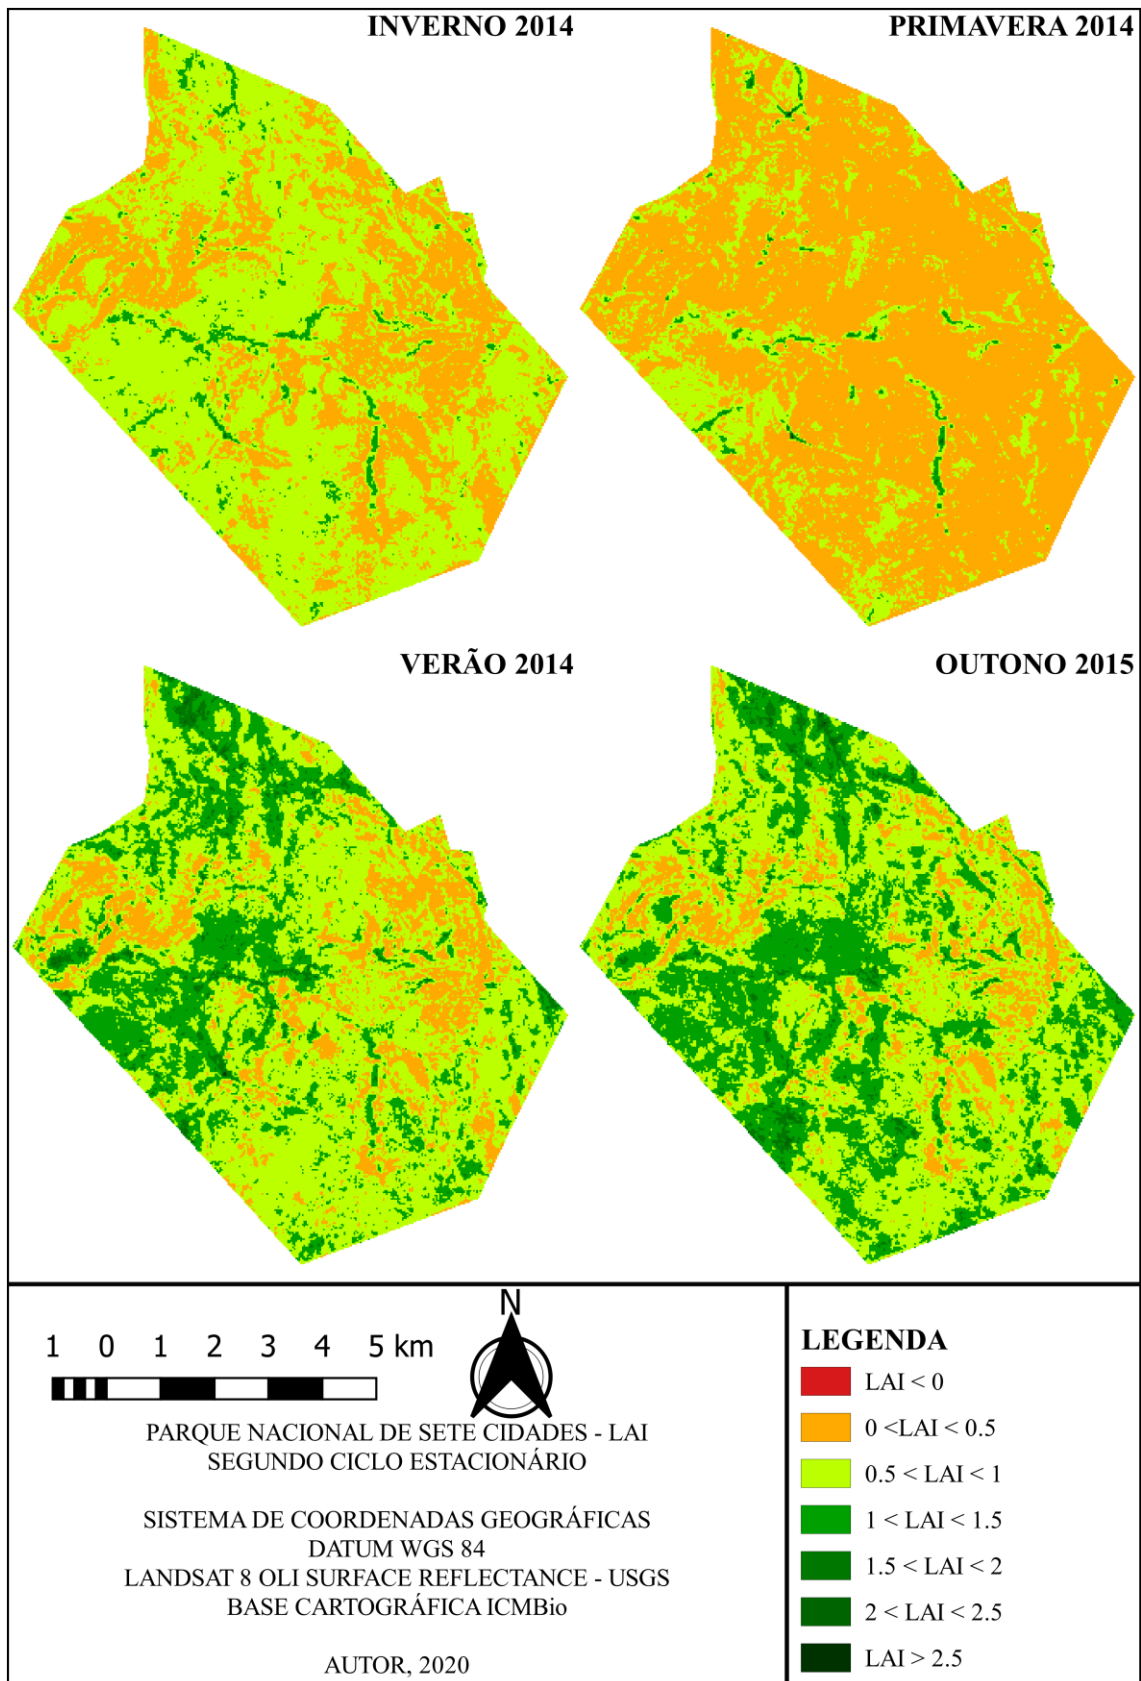


Figura 38. Parque Nacional de Sete Cidades – LAI do segundo ciclo estacionário 2014/2015



## 6 CONCLUSÃO

Diante dos estudos produzidos nesse trabalho pode-se constatar que a plataforma *GEE* mostra potencial e eficiência para a realização de estudos de análise ambiental em unidades de conservação como o Parque Nacional de Sete Cidades. Uma das principais vantagens observadas é a não necessidade de realização de *download* dos *rasters* a serem utilizados, como observado no trabalho de Paludo (2019), uma vez que estes estejam presentes no catálogo da plataforma como no caso das imagens *Landsat* e *CHIRPS*.

Outra vantagem é que uma vez escritas as rotinas para o estudo pretendido pode-se redefinir a área e o período de estudo com facilidade, como feito em outros softwares como *QGIS*, *ArcGIS*, *GRASS*, etc., que permitam o desenvolvimento de algoritmos em diversas linguagens como *R*, *Python* e *C++*. Além disso, por conta do processamento realizado em nuvem o trabalho da máquina local se torna menos oneroso facilitando a correção, inserção e exclusão de índices ou parâmetros pré-definidos no estudo, caso se decida por isto. As soluções desenvolvidas para a composição de mosaicos representativos e remoção de nuvens possibilitam a pesquisa em áreas de grande cobertura sazonal de nuvens e falhas de imagens.

Uma desvantagem seria a necessidade de uma conexão em banda larga para a realização dos processos propostos, visto que a plataforma só funciona *on-line*. Outra dificuldade de encontrar profissionais qualificados para o desenvolvimento da programação, sendo o Engenheiro Agrimensor (e nomenclaturas afins) uma opção viável dada à formação curricular da profissão na maioria dos cursos superiores.

Quanto ao comportamento da vegetação do PNSC, diante do estudo, é concluído que a vegetação se apresenta de forma distinta mediante as estações e disponibilidade de água no solo. Os índices de vegetação estudados rendem informações importantes para fundamentar ações de prevenção de riscos a diversidade ecológica do parque, seus recursos naturais e culturais.

Os resultados de *NDVI* demonstram gradientes de resposta de vegetação fotossinteticamente ativa, saturando nos maiores valores quanto mais chuvosa é a estação climática. Os resultados de *MSAVI 2* ajustam os valores de vegetação com a remoção da influência da reflectância do solo, caracterizando melhor as manchas de Caatinga e épocas secas. O *EVI 2*, com a remoção de ruídos atmosféricos e influência do solo, difere com maior distinção os tipos de vegetação por sua estrutura (por exemplo o dossel). Quando associados,

esses três índices ajudam a diferenciar as características locais das formações vegetais mediante as variações climatológicas. O *LAI* retona a quantidade de biomassa sobre a área de pixel e o *NDWI Gao* mostra a quantidade de água presente na estrutura vegetal, fatores que ajudam a compreender a relação dos índices anteriores com os dados pluviométricos.

Os aspectos discutidos não se esgotam na temática abordada, podendo, portanto alargar sua discussão e análise em trabalhos futuros, visto que sua pertinência e importância merecem atenção mais aprofundada, surgindo a necessidade de se realizar uma atualização da classificação da vegetação, bem como uma análise da variação de temperatura e da geomorfologia, comparando para novamente analisar as respostas dos índices de vegetação, de forma que também seja utilizado um espaçamento temporal mais significativo para observações mais consistentes que auxiliem nas investigações para manutenção e preservação da área analisada.

## ANEXO A

```

var l8sr = ee.ImageCollection("LANDSAT/LC08/C01/T1_SR"),
CHIRPS = ee.ImageCollection("UCSB-CHG/CHIRPS/DAILY"),
StudyArea = ee.FeatureCollection("users/diegotavares/PNSC"),
Sentinel = ee.ImageCollection("COPERNICUS/S2"),
table = ee.FeatureCollection("users/diegotavares/StudyAreaPNSC"),
geometry = /* color: #98ff00 */ /* shown: false */ /* displayProperties: [ { "type": "rectangle" } ] */
ee.Geometry.Polygon( [[[-46.04697655584904, -2.2719427666127268],[-46.04697655584904, -16.63462862592414],[-
34.03891991522404, -16.63462862592414],[-34.03891991522404, -2.2719427666127268]]], null, false),
piaui = /* color: #0b4a8b */ /* displayProperties: [ { "type": "rectangle" } ] */ ee.Geometry.Polygon( [[[-
41.76020533558269, -4.047929197326339], [-41.76020533558269, -4.1489503956082485],[-41.66647822376628, -
4.1489503956082485],[-41.66647822376628, -4.047929197326339]]], null, false);
Map.addLayer(StudyArea);
Map.centerObject(StudyArea,13);
// var MapBiomas = ee.Image('projects/mapbiomas-
workspace/public/collection4/mapbiomas_collection40_integration_v1')
// .select('classification_2013','classification_2014','classification_2015').clip(StudyArea)
// Map.addLayer(MapBiomas,{min:3, max:33,
// palette:['006400','32CD32','687537','76A5AF','29EEE4','77A605','935132','BBFCAC','45C2A5',
// 'B8AF4F','BDB76B','FFFFB2','FFD966','F6B26B','f99f40','E974ED','D5A6BD','C27BA0','FFFC3',
// 'EA9999','DD7E6B','af2a2a','FF99FF','0000FF','D5D5E5','dd497f','FF8C00','8A2BE2','29EEE4',
// '968c46','0000FF'], bands:['classification_2013']},MapBiomas');
//Function to get cloud-free image
function ClearImage(image) {image = image.reproject('EPSG: 4326', null, 30)
// Bits 3 and 5 are cloud shadow, and cloud, respectively.
var cloudShadowBitMask = 1 << 3;
var cloudsBitMask = 1 << 5;
// Get the pixel QA band.
var qa = image.select('pixel_qa');
// Both flags should be set to zero, indicating clear conditions.
var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0).and(qa.bitwiseAnd(cloudsBitMask).eq(0));
// Return the masked image, scaled to TOA reflectance, without the QA bands.
return image.updateMask(mask).divide(10000).select("B2","B3","B4","B5","B6","B7").copyProperties(image);}
var start = ee.Date('2013-06-21').millis();
var end = ee.Date('2015-06-21').millis();
// var countImages = CHIRPS.filterBounds(StudyArea).filterDate(start,end);
// print(countImages)
var startWinter13 = ee.Date('2013-06-21').millis();
var endWinter13 = ee.Date('2013-09-22').millis();
var startSpring13 = ee.Date('2013-09-22').millis();
var endSpring13 = ee.Date('2013-12-21').millis();
var startSummer13 = ee.Date('2013-12-21').millis();
var endSummer13 = ee.Date('2014-03-20').millis();
var startFall14 = ee.Date('2014-03-20').millis();
var endFall14 = ee.Date('2014-06-21').millis();
var startWinter14 = ee.Date('2014-06-21').millis();
var endWinter14 = ee.Date('2014-09-22').millis();
var startSpring14 = ee.Date('2014-09-22').millis();
var endSpring14 = ee.Date('2014-12-21').millis();
var startSummer14 = ee.Date('2014-12-21').millis();
var endSummer14 = ee.Date('2015-03-20').millis();
var startFall15 = ee.Date('2015-03-20').millis();
var endFall15 = ee.Date('2015-06-21').millis();
var rainfallDataCHIRPS = CHIRPS.filterDate(start, end).select('precipitation');
```

```

print(rainfallDataCHIRPS)
// Define arguments for the getFilmstripThumbURL function parameters.
var filmArgs = {dimensions: 200, region: geometry, framesPerSecond: 10, crs: 'EPSG:3857', min: 1, max: 17, palette:
['001137', '0aab1e', 'e7eb05', 'ff4a2d', 'e90000']};
// Print the animation to the console as a ui.Thumbnail using the above defined
// arguments. Note that ui.Thumbnail produces an animation when the first input
// is an ee.ImageCollection instead of an ee.Image.
print(ui.Thumbnail(rainfallDataCHIRPS, filmArgs));
// Print a URL that will produce the filmstrip when accessed.
print(rainfallDataCHIRPS.getVideoThumbURL(filmArgs));
// print(ui.Chart.image.series(rainfallDataCHIRPS.select('precipitation'), StudyArea, null, 30,'system:time_start'));
//var raindataCHIRPSwinter13 = CHIRPS.filterDate(startWinter13, endWinter13);
// print(ui.Chart.image.series(raindataCHIRPSwinter13.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSspring13 = CHIRPS.filterDate(startSpring13, endSpring13);
// print(ui.Chart.image.series(raindataCHIRPSspring13.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSsummer13 = CHIRPS.filterDate(startSummer13, endSummer13);
// print(ui.Chart.image.series(raindataCHIRPSsummer13.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSfall14 = CHIRPS.filterDate(startFall14, endFall14);
// print(ui.Chart.image.series(raindataCHIRPSfall14.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSwinter14 = CHIRPS.filterDate(startWinter14, endWinter14);
// print(ui.Chart.image.series(raindataCHIRPSwinter14.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSspring14 = CHIRPS.filterDate(startSpring14, endSpring14);
// print(ui.Chart.image.series(raindataCHIRPSspring14.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSsummer14 = CHIRPS.filterDate(startSummer14, endSummer14);
// print(ui.Chart.image.series(raindataCHIRPSsummer14.select('precipitation'), StudyArea,null, 30));
// var raindataCHIRPSfall15 = CHIRPS.filterDate(startFall15, endFall15);
// print(ui.Chart.image.series(raindataCHIRPSfall15.select('precipitation'), StudyArea,null, 30));
var indexCollection = function(img){ var ndwi_gao = img.normalizedDifference(['B5', 'B6']).rename('NDWI_Gao');
var ndwi = img.normalizedDifference(['B3', 'B5']).rename('NDWI');
var mndwi = img.normalizedDifference(['B3', 'B6']).rename('MNDWI');
var ndvi = img.normalizedDifference(['B5', 'B4']).rename('NDVI');
var msavi2 = (img.expression('((2 * NIR + 1 - ((2 * NIR + 1)**2 - 8 * (NIR -
RED)**(0.5)))/2',{RED:img.select('B4'),'NIR':img.select('B5')})).rename('MSAVI2'));
var evi = img.expression('2.5 * ((NIR - RED)/(NIR + 6 * RED - 7.5 * BLUE +
1))',{BLUE:img.select('B2'),'RED':img.select('B4'),'NIR':img.select('B5')})).rename('EVI');
var evi2 = img.expression('2.5 * ((NIR - RED)/(NIR + 2.4 * RED +
1))',{RED:img.select('B4'),'NIR':img.select('B5')})).rename('EVI2');
var lai = (((msavi2.subtract(0.69)).multiply(-1)).divide(0.59)).log()).multiply(-1).divide(0.91).rename('LAI');
var bsi = img.expression('((SWIR + RED) - (NIR + BLUE)) / ((SWIR + RED) + (NIR + BLUE))',{
'BLUE':img.select('B2'),'RED':img.select('B4'),'NIR':img.select('B5'),'SWIR':img.select('B7')}).rename('BSI');
var nbr = img.normalizedDifference(['B5', 'B7']).rename('NBR');
return
ndwi_gao.addBands(ndwi).addBands(mndwi).addBands(ndvi).addBands(msavi2).addBands(evi).addBands(evi2).addBands(l
ai).addBands(bsi).addBands(nbr));
var winter13 =
l8sr.filterBounds(StudyArea).filterDate(startWinter13,endWinter13).map(ClearImage).median().clip(StudyArea);
var indexesWinter13 =
ee.Image(indexCollection(winter13).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_st
art',startWinter13,'system:time_end',ee.Date('2013-09-21').millis()));
var spring13 =
l8sr.filterBounds(StudyArea).filterDate(startSpring13,endSpring13).map(ClearImage).median().clip(StudyArea);
var indexesSpring13 =
ee.Image(indexCollection(spring13).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_st
art',startSpring13,'system:time_end',ee.Date('2013-12-20').millis()));

```

```

var summer13 =
l8sr.filterBounds(StudyArea).filterDate(startSummer13,endSummer13).map(ClearImage).median().clip(StudyArea);
var indexesSummer13 =
ee.Image(indexCollection(summer13).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startSummer13,'system:time_end',ee.Date('2014-03-19').millis()));
var fall14 = l8sr.filterBounds(StudyArea).filterDate(startFall14,endFall14).map(ClearImage).median().clip(StudyArea);
var indexesFall14 =
ee.Image(indexCollection(fall14).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startFall14,'system:time_end',ee.Date('2014-06-20').millis()));
var winter14 =
l8sr.filterBounds(StudyArea).filterDate(startWinter14,endWinter14).map(ClearImage).median().clip(StudyArea);
var indexesWinter14 =
ee.Image(indexCollection(winter14).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startWinter14,'system:time_end',ee.Date('2014-09-21').millis()));
var spring14 =
l8sr.filterBounds(StudyArea).filterDate(startSpring14,endSpring14).map(ClearImage).median().clip(StudyArea);
var indexesSpring14 =
ee.Image(indexCollection(spring14).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startSpring14,'system:time_end',ee.Date('2014-12-20').millis()));
var summer14 =
l8sr.filterBounds(StudyArea).filterDate(startSummer14,endSummer14).map(ClearImage).median().clip(StudyArea);
var indexesSummer14 =
ee.Image(indexCollection(summer14).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startSummer14,'system:time_end',ee.Date('2015-03-19').millis()));
var fall15 = l8sr.filterBounds(StudyArea).filterDate(startFall15,endFall15).map(ClearImage).median().clip(StudyArea);
var indexesFall15 =
ee.Image(indexCollection(fall15).copyProperties(l8sr.first(),['system:time_start','system:time_end']).set('system:time_start',startFall15,'system:time_end',ee.Date('2015-06-20').millis()));
//Merge the collections of NDVI.
var colNDVI =
ee.ImageCollection([indexesWinter13.select('NDVI'),indexesSpring13.select('NDVI'),indexesSummer13.select('NDVI'),indexesFall14.select('NDVI'), indexesWinter14.select('NDVI'),indexesSpring14.select('NDVI'),indexesSummer14.select('NDVI'), indexesFall15.select('NDVI')]);
print(ui.Chart.image.series(colNDVI, StudyArea, ee.Reducer.mean(), 30));
// // //Merge the collections of NDWI_Gao.
// var colNDWI_Gao =
ee.ImageCollection([indexesWinter13.select('NDWI_Gao'),indexesSpring13.select('NDWI_Gao'),indexesSummer13.select('NDWI_Gao'),indexesFall14.select('NDWI_Gao'),
//
indexesWinter14.select('NDWI_Gao'),indexesSpring14.select('NDWI_Gao'),indexesSummer14.select('NDWI_Gao'), indexesFall15.select('NDWI_Gao')]);
// print(ui.Chart.image.series(colNDWI_Gao, StudyArea, ee.Reducer.mean(), 30));
//EVI REMOVIDO ATÉ CORREÇÃO DA REFLECTANCIA DA BANDA 2
// //Merge the collections of EVI.
// var colEVI =
ee.ImageCollection([indexesWinter13.select('EVI'),indexesSpring13.select('EVI'),indexesSummer13.select('EVI'),indexesFall14.select('EVI'),
//
indexesWinter14.select('EVI'),indexesSpring14.select('EVI'),indexesSummer14.select('EVI'), indexesFall15.select('EVI')]);
// print(ui.Chart.image.series(colEVI, StudyArea, ee.Reducer.mean(), 30));
// //Merge the collections of EVI2.
// var colEVI2 =
ee.ImageCollection([indexesWinter13.select('EVI2'),indexesSpring13.select('EVI2'),indexesSummer13.select('EVI2'),indexesFall14.select('EVI2'),

```



```

//           indexesWinter14.select('EVI2'),indexesSpring14.select('EVI2'),indexesSummer14.select('EVI2'),
indexesFall15.select('EVI2'));
// print(ui.Chart.image.series(colEVI2, StudyArea, ee.Reducer.mean(), 30));
// //Merge the collections of MSAVI2.
// var colMSAVI2 =
ee.ImageCollection([indexesWinter13.select('MSAVI2'),indexesSpring13.select('MSAVI2'),indexesSummer13.select('MSAVI2'),
indexesFall14.select('MSAVI2'),
//
indexesWinter14.select('MSAVI2'),indexesSpring14.select('MSAVI2'),indexesSummer14.select('MSAVI2'),
indexesFall15.select('MSAVI2'))];
// print(ui.Chart.image.series(colMSAVI2, StudyArea, ee.Reducer.mean(), 30));
// //Merge the collections of LAI.
// var colLAI =
ee.ImageCollection([indexesWinter13.select('LAI'),indexesSpring13.select('LAI'),indexesSummer13.select('LAI'),indexesFall14.select('LAI'),
//
indexesWinter14.select('LAI'),indexesSpring14.select('LAI'),indexesSummer14.select('LAI'),
indexesFall15.select('LAI'))];
// print(ui.Chart.image.series(colLAI, StudyArea, ee.Reducer.mean(), 30));
//BSI REMOVIDO ATÉ CORREÇÃO DA REFLECTANCIA DA BANDA 2
// //Merge the collections of BSI.
// var colBSI =
ee.ImageCollection([indexesWinter13.select('BSI'),indexesSpring13.select('BSI'),indexesSummer13.select('BSI'),indexesFall14.select('BSI'),
//
indexesWinter14.select('BSI'),indexesSpring14.select('BSI'),indexesSummer14.select('BSI'),
indexesFall15.select('BSI'))];
// print(ui.Chart.image.series(colBSI, StudyArea, ee.Reducer.mean(), 30));
// //Merge the collections of NBR.
// var colNBR =
ee.ImageCollection([indexesWinter13.select('NBR'),indexesSpring13.select('NBR'),indexesSummer13.select('NBR'),indexesFall14.select('NBR'),
//
indexesWinter14.select('NBR'),indexesSpring14.select('NBR'),indexesSummer14.select('NBR'),
indexesFall15.select('NBR'))];
// print(ui.Chart.image.series(colNBR, StudyArea, ee.Reducer.mean(), 30));
var NDVI =
indexesFall15.select(['NDVI'],['NDVIfall2015']).addBands(indexesSummer14.select(['NDVI'],['NDVIsummer2014'])).addBands
(indexesSpring14.select(['NDVI'],['NDVIspring2014'])).addBands(indexesWinter14.select(['NDVI'],['NDVIwinter2014'])).addB
ands(indexesFall14.select(['NDVI'],['NDVIfall2014'])).addBands(indexesSummer13.select(['NDVI'],['NDVIsummer2013'])).add
Bands(indexesSpring13.select(['NDVI'],['NDVIspring2013'])).addBands(indexesWinter13.select(['NDVI'],['NDVIwinter2013']
));
;
Export.image.toDrive({image: NDVI, description: 'NDVI', folder: 'ParnadeSeteCidadesFinal', region: StudyArea, scale: 30,
crs:'EPSG:4326', maxPixels: 500000000});
var NDWI_Gao =
indexesFall15.select(['NDWI_Gao'],['NDWI_Gaofall2015']).addBands(indexesSummer14.select(['NDWI_Gao'],['NDWI_Gaosu
mmer2014'])).addBands(indexesSpring14.select(['NDWI_Gao'],['NDWI_Gaospring2014'])).addBands(indexesWinter14.selec
t(['NDWI_Gao'],['NDWI_Gaowinter2014'])).addBands(indexesFall14.select(['NDWI_Gao'],['NDWI_Gaofall2014'])).addBands(
indexesSummer13.select(['NDWI_Gao'],['NDWI_Gaosummer2013'])).addBands(indexesSpring13.select(['NDWI_Gao'],['ND
WI_Gaospring2013'])).addBands(indexesWinter13.select(['NDWI_Gao'],['NDWI_Gaowinter2013']));
Export.image.toDrive({image: NDWI_Gao, description: 'NDWI_Gao', folder: 'ParnadeSeteCidadesFinal', region: StudyArea,
scale: 30, crs:'EPSG:4326', maxPixels: 500000000});
// var EVI = indexesFall15.select(['EVI'],['EVIfall2015']).addBands(indexesSummer14.select(['EVI'],['EVIsummer2014']
))
// .addBands(indexesSpring14.select(['EVI'],['EVIspring2014'])).addBands(indexesWinter14.select(['EVI'],['EVIwinter2014']
))
// .addBands(indexesFall14.select(['EVI'],['EVIfall2014'])).addBands(indexesSummer13.select(['EVI'],['EVIsummer2013']
))
// .addBands(indexesSpring13.select(['EVI'],['EVIspring2013'])).addBands(indexesWinter13.select(['EVI'],['EVIwinter2013']
));
// Export.image.toDrive({image: EVI, description: 'EVI', folder: 'ParnadeSeteCidades', region: StudyArea, scale: 30,
// crs:'EPSG:4326', maxPixels: 500000000});

```

```

// var EVI2 = indexesFall15.select(['EVI2'],['EVI2fall2015']).addBands(indexesSummer14.select(['EVI2'],['EVI2summer2014']))
// .addBands(indexesSpring14.select(['EVI2'],['EVI2spring2014']))
//.addBands(indexesWinter14.select(['EVI2'],['EVI2winter2014']))
//.addBands(indexesFall14.select(['EVI2'],['EVI2fall2014']))
//.addBands(indexesSummer13.select(['EVI2'],['EVI2summer2013']))
//.addBands(indexesSpring13.select(['EVI2'],['EVI2spring2013']))
//.addBands(indexesWinter13.select(['EVI2'],['EVI2winter2013']));
// Export.image.toDrive({image: EVI2, description: 'EVI2', folder: 'ParnadeSeteCidadesFinal', region: StudyArea, scale: 30,
// crs:'EPSG:4326', maxPixels: 500000000});
// var MSAVI2 = indexesFall15.select(['MSAVI2'],['MSAVI2fall2015'])
//.addBands(indexesSummer14.select(['MSAVI2'],['MSAVI2summer2014']))
//.addBands(indexesSpring14.select(['MSAVI2'],['MSAVI2spring2014']))
//.addBands(indexesWinter14.select(['MSAVI2'],['MSAVI2winter2014']))
//.addBands(indexesFall14.select(['MSAVI2'],['MSAVI2fall2014']))
//.addBands(indexesSummer13.select(['MSAVI2'],['MSAVI2summer2013']))
// .addBands(indexesSpring13.select(['MSAVI2'],['MSAVI2spring2013']))
// .addBands(indexesWinter13.select(['MSAVI2'],['MSAVI2winter2013']));
// Export.image.toDrive({image: MSAVI2, description: 'MSAVI2', folder: 'ParnadeSeteCidadesFinal', region: StudyArea,
// scale: 30, crs:'EPSG:4326', maxPixels: 500000000});
// var LAI = indexesFall15.select(['LAI'],['LAIfall2015']). addBands(indexesSummer14.select(['LAI'],['LAIsummer2014']))
//.addBands(indexesSpring14.select(['LAI'],['LAIspring2014'])) .addBands(indexesWinter14.select(['LAI'],['LAIwinter2014']))
// .addBands(indexesFall14.select(['LAI'],['LAIfall2014'])) addBands(indexesSummer13.select(['LAI'],['LAIsummer2013']))
// .addBands(indexesSpring13.select(['LAI'],['LAIspring2013'])).addBands(indexesWinter13.select(['LAI'],['LAIwinter2013']));
// Export.image.toDrive({image: LAI, description: 'LAI', folder: 'ParnadeSeteCidadesFinal', region: StudyArea, scale: 30,
// crs:'EPSG:4326', maxPixels: 500000000});
// var BSI = indexesFall15.select(['BSI'],['BSIfall2015']).addBands(indexesSummer14.select(['BSI'],['BSIsummer2014']))
//.addBands(indexesSpring14.select(['BSI'],['BSIspring2014'])).addBands(indexesWinter14.select(['BSI'],['BSIwinter2014']))
//.addBands(indexesFall14.select(['BSI'],['BSIfall2014'])).addBands(indexesSummer13.select(['BSI'],['BSIsummer2013']))
//.addBands(indexesSpring13.select(['BSI'],['BSIspring2013'])).addBands(indexesWinter13.select(['BSI'],['BSIwinter2013']));
// Export.image.toDrive({image: BSI, description: 'BSI', folder: 'ParnadeSeteCidades', region: StudyArea, scale: 30,
// crs:'EPSG:4326', maxPixels: 500000000});
// var NBR = indexesFall15.select(['NBR'],['NBRfall2015']).addBands(indexesSummer14.select(['NBR'],['NBRsummer2014']))
//.addBands(indexesSpring14.select(['NBR'],['NBRspring2014']))
//.addBands(indexesWinter14.select(['NBR'],['NBRwinter2014']))
//.addBands(indexesFall14.select(['NBR'],['NBRfall2014'])).addBands(indexesSummer13.select(['NBR'],['NBRsummer2013']))
// .addBands(indexesSpring13.select(['NBR'],['NBRspring2013']))
//.addBands(indexesWinter13.select(['NBR'],['NBRwinter2013']));
// Export.image.toDrive({image: NBR, description: 'NBR', folder: 'ParnadeSeteCidades', region: StudyArea, scale: 30,
// crs:'EPSG:4326', maxPixels: 500000000});
// var getAreas = function(img){ var areas = img.reduceRegion({reducer:ee.Reducer.count(),
// geometry: StudyArea.geometry(),scale: 30, maxPixels:1e13}).get('NBR')
//areas = ee.Number(areas).multiply(900).divide(10000) return areas;
// var iw13 = getAreas(indexesFall15.select('NDWI_Gao'));
// print(iw13)
// var iw13lte02 = getAreas(indexesFall15.select('NDWI_Gao').lte(-0.20).selfMask());
// print(iw13lte02.divide(iw13).multiply(100))
// var iw13lte03 = getAreas(indexesFall15.select('NDWI_Gao').lte(-0.15)
// .and(indexesFall15.select('NDWI_Gao').gt(-0.20)).selfMask());
// print(iw13lte03.divide(iw13).multiply(100))
// var iw13lte04 = getAreas(indexesFall15.select('NDWI_Gao').lte(-0.10)
// .and(indexesFall15.select('NDWI_Gao').gt(-0.15)).selfMask());
// print(iw13lte04.divide(iw13).multiply(100))
// var iw13lte05 = getAreas(indexesFall15.select('NDWI_Gao').lte(0)
// .and(indexesFall15.select('NDWI_Gao').gt(-0.10)).selfMask());
// print(iw13lte05.divide(iw13).multiply(100))

```

```

// var iw13lte06 = getAreas(indexesFall15.select('NDWI_Gao').lte(0.15)
// .and(indexesFall15.select('NDWI_Gao').gt(0)).selfMask());
// print(iw13lte06.divide(iw13).multiply(100))
// var iw13lte07 = getAreas(indexesFall15.select('NDWI_Gao').lte(0.30)
// .and(indexesFall15.select('NDWI_Gao').gt(0.15)).selfMask());
// print(iw13lte07.divide(iw13).multiply(100))
// var iw13gt07 = getAreas(indexesFall15.select('NDWI_Gao').gt(0.30).selfMask());
// print(iw13gt07.divide(iw13).multiply(100))
//paletteNDVI: 0000ff,ff0000,ff0000,ffb100,ffff00,bfff00,00ff00,00bc00,007700,007700,007700
//print(NBR.reduceRegion({reducer: ee.Reducer.minMax(),geometry: StudyArea, scale:30}))
// Map.addLayer(NDVI.select('NDVIwinter2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'NDVIwi2013',false)
// Map.addLayer(NDVI.select('NDVIspring2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'NDVIspr2013',false)
// Map.addLayer(NDVI.select('NDVIsummer2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'NDVIsu2013',false)
// Map.addLayer(NDVI.select('NDVIfall2014'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'NDVIfa2014',false)
// Map.addLayer(EVI2.select('EVI2winter2013'),{min: 0.2,max: 0.7, palette: ['ce0000','ff0000','ffb100',
// 'ffff00','bfff00','00ff00','007700','007700','007700','007700','007700']},'EVI2wi2013',false)
// Map.addLayer(EVI2.select('EVI2spring2013'),{min: 0.2,max: 0.7, palette: ['ce0000','ff0000','ffb100',
// 'ffff00','bfff00','00ff00','007700','007700','007700','007700','007700']},'EVI2sp2013',false)
// Map.addLayer(EVI2.select('EVI2summer2013'),{min: 0.2,max: 0.7, palette: ['ce0000','ff0000','ffb100',
// 'ffff00','bfff00','00ff00','007700','007700','007700','007700','007700']},'EVI2su2013',false)
// Map.addLayer(EVI2.select('EVI2fall2014'),{min: 0.2,max: 0.7, palette: ['ce0000','ff0000','ffb100',
// 'ffff00','bfff00','00ff00','007700','007700','007700','007700','007700']},'EVI2fa2014',false)
// Map.addLayer(MSAVI2.select('MSAVI2winter2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'MSAVI2wi2013',false)
// Map.addLayer(MSAVI2.select('MSAVI2spring2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'MSAVI2sp2013',false)
// Map.addLayer(MSAVI2.select('MSAVI2summer2013'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'MSAVI2su2013',false)
// Map.addLayer(MSAVI2.select('MSAVI2fall2014'),{min: 0,max: 1, palette: ['0000ff','ff0000','ff0000',
// 'ffb100','ffff00','bfff00','00ff00','00bc00','007700','007700','007700']},'MSAVI2fa2014',false)
// Map.addLayer(LAI.select('LAIwinter2013'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIwi2013',false)
// Map.addLayer(LAI.select('LAIspring2013'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIspr2013',false)
// Map.addLayer(LAI.select('LAIsummer2013'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIsu2013',false)
// Map.addLayer(LAI.select('LAIfall2014'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIfa2013',false)
// Map.addLayer(LAI.select('LAIwinter2014'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIwi2014',false)
// Map.addLayer(LAI.select('LAIspring2013'),{min: 0, max: 3, palette:['ff0000','e7ce55','fff700',
// '00ff00','00d600','00bb00','007500']},'LAIwi2013',false)
// Map.addLayer(NDWI_Gao.select('NDWI_Gaowinter2013'),{min: -0.20,max: 0.40, palette: ['ff0000','ff9900','ffff00',
// 'ffffff','ffffff','00ff00','00ff00','00ff00','00bb00','00bb00','00bb00','007700','007700']},'NDWI_Gaowi2013',false)
// Map.addLayer(NDWI_Gao.select('NDWI_Gaospring2013'),{min: -0.20,max: 0.40, palette: ['ff0000','ff9900','ffff00',
// 'ffffff','ffffff','00ff00','00ff00','00ff00','00bb00','00bb00','00bb00','007700','007700']},'NDWI_Gaospr2013',false)
// Map.addLayer(NDWI_Gao.select('NDWI_Gaosummer2013'),{min: -0.20,max: 0.40, palette: ['ff0000','ff9900','ffff00',
// 'ffffff','ffffff','00ff00','00ff00','00ff00','00bb00','00bb00','00bb00','007700','007700']},'NDWI_Gaosu2013',false)
// Map.addLayer(NDWI_Gao.select('NDWI_Gaofall2014'),{min: -0.20,max: 0.40, palette: ['ff0000','ff9900','ffff00',
// 'ffffff','ffffff','00ff00','00ff00','00ff00','00bb00','00bb00','00bb00','007700','007700']},'NDWI_Gaofa2014',false)

```

```

var sentinel = Sentinel.filterBounds(StudyArea).sort('CLOUD').first().clip(StudyArea).select('B4','B3','B2').reproject('EPSG:4326', null, 10)
//print(Sentinel.filterBounds(StudyArea).sort('CLOUD').first())
//Map.addLayer(sentinel,{min:500, max: 3000, bands:['B4','B3','B2'],'sentinel'})
// Export.image.toDrive({image: sentinel, description: 'sentinel', folder: 'ParnadeSeteCidadesFinal', region: StudyArea,
// scale: 10, crs:'EPSG:4326', maxPixels: 500000000});
var l8srcol = l8sr.filterDate(start, end).filterBounds(StudyArea).sort('system:time_start');
// Define visualization arguments.
var visArgs = {bands: ['B4', 'B3', 'B2'], min: 0, max: 3000};
// Define a function to convert an image to an RGB visualization image and copy
// properties from the original image to the RGB image.
var visFun = function(img) {return img.visualize(visArgs).clip(piaui).copyProperties(img, img.propertyNames());};
// Map over the image collection to convert each image to an RGB visualization
// using the previously defined visualization function.
var l8srcolVis = l8srcol.map(visFun);
print(l8srcol)
//Map.addLayer(table)
// Define arguments for animation function parameters.
var videoArgs = {bands: ['vis-red','vis-green','vis-blue'], dimensions: 600, region: piaui, framesPerSecond: 1, crs: 'EPSG:3857',
min: 0, max: 255};
// Print the animation to the console as a ui.Thumbnail using the above defined
// arguments. Note that ui.Thumbnail produces an animation when the first input
// is an ee.ImageCollection instead of an ee.Image.
//print(ui.Thumbnail(l8srcolVis));
// Alternatively, print a URL that will produce the animation when accessed.
print(l8srcolVis.getVideoThumbURL(videoArgs));
var colMedian = ee.ImageCollection.fromImages([winter13,spring13,summer13,winter14,spring14,summer14,fall15])
var visArgs1 = {bands: ['B4', 'B3', 'B2'], min: 0, max: 0.3};
var visFun1 = function(img) {return img.visualize(visArgs1).clip(piaui).copyProperties(img, img.propertyNames());};
// Map over the image collection to convert each image to an RGB visualization
// using the previously defined visualization function.
var colMedianVis = colMedian.map(visFun1);
print(colMedian)
//Map.addLayer(table)
// Define arguments for animation function parameters.
var videoArgs1 = { bands: ['vis-red','vis-green','vis-blue'], dimensions: 600, region: piaui, framesPerSecond: 2, crs:
'EPSG:3857', min: 0, max: 255,};
// Alternatively, print a URL that will produce the animation when accessed.
print(colMedianVis.getVideoThumbURL(videoArgs1));

```

## REFERÊNCIAS BIBLIOGRÁFICAS

AIRES, U. R. V. ; NETO, J. de O. M.; CAMPOS, J. A. **Uso de NDVI para análise do comportamento do regime de vazões do Rio Paraopeba, MG.** REVISTA SCIENTIA AGRARIA Versão On-line ISSN 1983-2443 Versão Impressa ISSN 1519-1125 SA vol. 18 n°. 3 Curitiba Jul/Set. 2017 p. 08-19

BECKER, W.R.; CAON, I. L.; CATTANI, C. E. V.; MERCANTE, E.; Jerry Adriani JOHANN, J. A.; GANASCINI, D.; PRUDENTE, V. H. R. **Mediana e desvio padrão do perfil espectro-temporal de NDVI como parâmetros de classificação.** Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 14 a 17 de Abril de 2019.

BIFFI, L. J.; JARENKOW, G. L.; FRANCHINI, R. L.; VIEIRA, R. M.; NETO, S. L. R.; CORDEIRO, M. T. A.. **Comparação de modelos digitais de elevação de SRTM e ASTER com modelo de elevação de grande escala do município de Lages – SC.** Departamento de Engenharia Ambiental, Universidade do Estado de Santa Catarina – UDESC/CAV. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.

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

BORATTO, I. M. de P.; GOMIDE R. L. **Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais.** Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.

BRÉDA, N.J.J. **Ground-based measurements of leaf area index: a review of methods, instruments and current controversies.** Journal of Experimental Botany, v.54, n.392, p.2403-2417, 2003.

DE FRANÇA E SILVA, N. R.; DA SILVA, H. P.; ALVES, R. B. DE O. **Avaliação do NDVI, SAVI e IAF na ilha de Itapessoca, Goiana, Pernambuco em períodos diferentes de pluviosidade.** Anais do XXVII Congresso Brasileiro de Cartografia e XXVI Expositiva 6 a 9 de novembro de 2017, SBC, Rio de Janeiro - RJ, p. 897-902.

DE PAULA, S. C.; VEDOVATO, L. B.; DA SILVA, G. B. S.; VICENTE, L. E.; **Comparação entre índices espectrais EVI e EVI2 para discriminação de pastagens plantadas e naturais.** VII Congresso Interinstitucional de Iniciação Científica – CIIC. Campinas, SP, Brasil, 2013.

DIOGO, A. M; DA FONSECA, E. L.; NHONGO, E. J. S. **Identificação da dinâmica da fenologia da cobertura vegetal do sul de Angola com dados orbitais.** Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 14 a 17 de Abril de 2019.

GAMEIRO S., TEIXEIRA C.P.B., SILVA NETO T.A.; LOPES M.F.L., DUARTE C.R., SOUTO M.V.S., ZIMBACK C.R.L.. **Avaliação da cobertura vegetal por meio de índices**

**de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE.** Terræ, 13(1-2):15-22, 2016.

GANEM, K. A.; BAPTISTA, G. M. de M.; ROCHA, W. de J. S. da F.; VASCONCELLOS, R. N.; ROSA, M. R.; DE SOUZA, D. T. M. **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 (2017), Edição de Fotogrametria e Sensoriamento Remoto, No 69/6: 1053-1074 Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto ISSN: 1808-0936.

GHILANI, C. D.; WOLF, P. R. **Elementary surveying: an introduction to geomatics.** 13. ed. 2012.

INSTITUTO BRASILEIRO DE DESENVOLVIMENTO FLORESTAL. **Plano de Manejo Parque Nacional de Sete Cidades.** Brasília, DF, Brasil, 1979.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE. Disponível em: <<http://www.icmbio.gov.br/portal/parna-de-sete-cidades>> Acessado em: 13/01/2020  
INSTITUTO DE ASTRONOMIA, GEOFÍSICA E CIÊNCIAS CLIMÁTICAS. Disponível em: <<https://www.iag.usp.br/astronomia/inicio-das-estacoes-do-ano>> acesso em: 13/01/2020.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres** (Segunda edição), São José dos Campos, São Paulo, Brasil: Parêntese, 2009.

JIANG, Z., et al., **Development of a two-band enhanced vegetation index without a blue band.** Elsevier Remote Sensing of Environment, 2008, doi:10.1016/j.rse.2008.06.006  
Disponível em: <[https://www.researchgate.net/publication/223925282\\_Development\\_of\\_a\\_two-band\\_enhanced\\_vegetation\\_index\\_without\\_a\\_blue\\_band](https://www.researchgate.net/publication/223925282_Development_of_a_two-band_enhanced_vegetation_index_without_a_blue_band)> Acesso em: 15/01/2020.

MENDES, J.M.; SANTOS, F.A.dos. **Diagnóstico do meio natural em unidades de conservação: o caso do parque nacional de Sete Cidades (Piauí).** Revista CC&T/UECE do Centro de Ciência e Tecnologia da Universidade Estadual do Ceará. Fortaleza/CE, v. 1, n.3, p. 78-89, jul./dez. 2019. Disponível em: <https://revistas.uece.br/index.php/CCiT>.

MMA. Disponível em:<<https://www.mma.gov.br/areas-protegidas/unidades-de-conservacao/sistema-nacional-de-ucs-snuc.html>>acesso em: 22/03/2020

NASAA. Disponível em:<<https://landsat.gsfc.nasa.gov/about/history/>>acesso em: 18/02/2020

NASAb. Disponível em: < <https://landsat.gsfc.nasa.gov/landsat-1/>> acesso em: 18/02/2020

NASAc. Disponível em: < <https://landsat.gsfc.nasa.gov/landsat-2/>> acesso em: 18/02/2020

NASAd. Disponível em: < <https://landsat.gsfc.nasa.gov/landsat-3/>> acesso em: 18/02/2020

NASAE. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-4/>> acesso em: 18/02/2020

NASAf. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-5/>> acesso em: 18/02/2020

NASAg. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-6/>> acesso em: 18/02/2020

NASAh. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-7/>> acesso em: 18/02/2020

NASAi. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-8/>> acesso em: 18/02/2020

NOAA. Disponível em:

<[https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php)>  
acesso em: 13/01/2020

NOVO, E. M. L. de M.; PONZONI, F. J. **Introdução ao sensoriamento remoto**. Instituto de Pesquisas Espaciais – INPE. São José dos Campos, SP, Brasil, 2001.

OLIVEIRA, M. E. A.; FARIAS, R. R. S.; CASTRO, A. A. J. F.; MARTINS, F. R.; **Classificação e caracterização dos tipos vegetacionais do Parque Nacional de Sete Cidades**, Piauí, Brasil. Biodiversidade e Ecótonos da Região Setentrional do Piauí, Teresina, 5: 66-89, 2010

OLIVEIRA, M. E. A.; MARTINS, F. R.; CASTRO, A. A. J. F.; DOS SANTOS, J. R. **Classes de cobertura vegetal do Parque Nacional de Sete Cidades**. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 1775-1783.

PALUDO, A. **Google Earth Engine para mapeamento de culturas agrícolas no Paraná**. Centro de Ciências Exatas e Tecnológicas, UNIOESTE. Cascavel, PR, BR, 2019.

PAREDES-TREJO, F. J.; BARBOSA, H.A.; KUMARC,T.V.L. **Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil**. Journal of Arid Environments Volume 139, April 2017, Pages 26-40.

PESSOA, L. N.; DA SILVA, Z. G.; DE ALBUQUERQUE, E. M.; LOURENÇO, A. M. G. **Impactos da seca 2012-2016 sobre os recursos hídricos na microrregião da Serra de Teixeira – PB**. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 14 a 17 de Abril de 2019.

PINHEIRO, E. da S. **COMPARAÇÃO ENTRE DADOS ALTIMÉTRICOS SHUTTLE RADAR TOPOGRAPHY MISSION, CARTAS TOPOGRÁFICAS E GPS: NUMA ÁREA COM RELEVO ESCARPADO**. Escola de Engenharia de São Carlos – Universidade de São Paulo. Revista Brasileira de Cartografia No 58/01, 2006. (ISSN 1808-0936).

RAMBO, E. M.; SILVA, L. C. de A.; BECKER, W. R.; RICHETTI, J.; BORTOLINI, J.; JOHANN, J. A.; MERCANTE, E. **Processamento e classificação de imagens Landsat-8 para uso e ocupação do município de Tupãssi - PR utilizando o Google Earth Engine**. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 14 a 17 de Abril de 2019.

SANTOS, F. de A. dos **Uso de imagens Landsat para avaliação da cobertura vegetal do Parque Nacional de Sete Cidades (PI), Nordeste, Brasil**. Cadernos Cajuína, V. 1, N. 3, 2016, p.24 - 35. ISSN: 2448-0916.

SANTOS, P. R. A. dos; GABOARDI, C.; OLIVEIRA, L. C. de. **Avaliação da precisão vertical dos modelos SRTM para a Amazônia**. Instituto Brasileiro de Geografia e

Estatística (IBGE), Instituto Militar de Engenharia (IME). *Revista Brasileira de Cartografia*, v. 1, n. 58, 2009.

SILVA FILHO, R. da. **Reconstrução de séries temporais de NDVI para uma área de caatinga**. Centro de Tecnologia e Recursos Naturais, UFCG .Campina Grande, PB, Brasil, 2019.

SOBRINHA, L. A. **Classificação semiautomática de imagens de satélites e suas implicações na modelação do escoamento superficial direto em bacias urbanas**. Escola de Engenharia de São Carlos – USP. São Carlos, SP, Brasil, 2016.

SOUZA, G. M. de; MATRICARDI, E. A. T. **Análise comparativa dos modelos de elevação SRTM, ASTER GDEM e TOPODATA para estimar o fator topográfico (LS) da USLE**. Universidade de Brasília – Departamento de Engenharia Florestal (UnB/EFL). Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.

SOUZA, J.M. de. **ANÁLISE DA QUALIDADE CARTOGRÁFICA DOS DADOS DA SHUTTLE RADAR TOPOGRAPHY MISSION – SRTM**. Dissertação de Mestrado. Programa de Pós-Graduação em Engenharia Civil – PPGEC, Universidade Federal de Santa Catarina, Florianópolis, 2006. 116p.

SOUZA, R. B. **Sensoriamento Remoto: conceitos fundamentais e plataformas**. Centro Regional do Sul de Pesquisas Espaciais – CRS, INPE. Santa Maria, RS, Brasil, 2010  
USGSa. Disponível em: <[https://www.usgs.gov/land-resources/nli/landsat/landsat-8?qt-science\\_support\\_page\\_related\\_con=0#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/land-resources/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con)> acesso em: 10/02/2020.

USGSb **LANDSAT 8 SURFACE REFLECTANCE CODE (LASRC) PRODUCT GUIDE**. V. 5. Sioux Falls, South Dakota, USA, mai. 2019

USGSc. **Landsat 8 (L8) Data Users Handbook**. V.5. Sioux Falls, South Dakota, USA, nov. 2019.

WATSON, D. J. **Comparative physiological studies on growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years**. *Annals of Botany*, v. 11, p. 41-76, 1947.

XUE, J.; SU, B. **Significant Remote Sensing Vegetation Indices: a Review of Developments and Applications**. Hindawi, *Jornal of Sensors*, 2017.

YOUNG, N. E.; ANDERSON, R. S.; CHIGNELL, S. M.; VORSTER, A. G.; LAWRENCE, R.; EVANGELISTA, P. H. **A survival guide to Landsat preprocessing**. *Ecology*, 98(4), 2017, pp. 920–932