



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS  
UNIDADE ACADÊMICA DE ENGENHARIA CIVIL**

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL  
ÁREA DE CONCENTRAÇÃO: RECURSOS HÍDRICOS E SANEAMENTO  
AMBIENTAL**

**RECONSTRUÇÃO DE SÉRIES TEMPORAIS DE NDVI PARA UMA ÁREA DE  
CAATINGA**

Dissertação de Mestrado

**RIVAILDO DA SILVA FILHO**

Campina Grande-PB  
Fevereiro de 2019

**RIVAILDO DA SILVA FILHO**

**RECONSTRUÇÃO DE SÉRIES TEMPORAIS DE NDVI PARA UMA ÁREA DE  
CAATINGA**

Dissertação apresentada à Universidade Federal de  
Campina Grande, para a obtenção do título de Mestre em  
Engenharia Civil e Ambiental, na área de concentração:  
Recursos Hídricos e Saneamento Ambiental.

Orientadores: Carlos de Oliveira Galvão

Rochele Sheila Vasconcelos

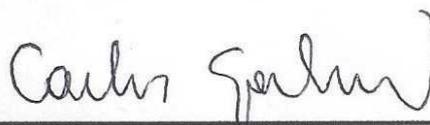
Campina Grande-PB  
Fevereiro de 2019

**RIVAILDO DA SILVA FILHO**

**RECONSTRUÇÃO DE SÉRIES TEMPORAIS DE NDVI PARA UMA ÁREA DE  
CAATINGA**

Dissertação aprovada em 19 de fevereiro de 2019.

COMISSÃO EXAMINADORA



---

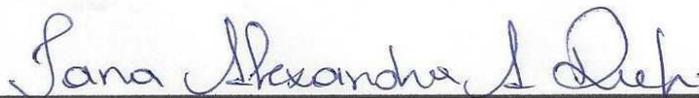
Prof. Dr. Carlos de Oliveira Galvão  
Orientador

Unidade Acadêmica de Engenharia Civil – UFCG



---

Dra. Rochele Sheila Vasconcelos  
Co-orientadora



---

Prof. Dra. Iana Alexandra Alves Rufino  
Examinadora interna

Unidade Acadêmica de Engenharia Civil – UFCG



---

Dr. Victor Hugo Rabelo Coelho  
Examinador externo

Departamento de Engenharia Civil e Ambiental - UFPB

Campina Grande-PB

Fevereiro de 2019

S586r Silva Filho, Rivaldo da.  
Reconstrução de séries temporais de NDVI para uma área de caatinga / Rivaldo da Silva Filho. – Campina Grande, 2019.  
96 f. : il. color.

Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2019.  
"Orientação: Prof. Dr. Carlos de Oliveira Galvão, Prof.<sup>a</sup> Dr.<sup>a</sup> Rochele Sheila Vasconcelos".  
Referências.

1. Semiárido. 2. Índice de vegetação. 3. Cauchy. 4. Preenchimento de falhas. I. Galvão, Carlos de Oliveira. II. Vasconcelos, Rochele Sheila. III. Título.

CDU 502(043)

*Dedico este trabalho aos meus pais, Rivaildo da Silva e Cleonice Sousa e Silva pelo apoio e carinho e por propiciarem esta oportunidade de concretizar mais um sonho.*

## AGRADECIMENTOS

Agradeço primeiramente a Deus, por ser presente sempre em minha vida, guiando meus caminhos.

À minha família, em especial aos meus pais, Rivaildo e Cleonice e a minha irmã Nelmara por todo apoio, incentivo e força que me motivaram durante todos os desafios de minha vida.

Ao meu orientador, Prof.º Carlos de Oliveira Galvão, pela sua competência, estímulo, orientação e confiança para realização deste trabalho.

À minha co-orientadora, Rochele Sheila Vasconcelos, pelos conselhos e sugestões.

Aos membros da banca examinadora, pela dedicação de seu tempo na contribuição deste trabalho.

A todos os professores, funcionários e colegas do Laboratório de Hidráulica II, afetuosamente chamado de BU.

A todos que contribuíram direta ou indiretamente para a elaboração deste estudo.

Muito obrigado!

“Sonhar é verbo  
É seguir, é pensar, é inspirar  
É fazer força, insistir  
É lutar, é transpirar  
São mil verbos  
Que vem antes do verbo realizar  
Sonhar é ser sempre meio  
É ser meio indeciso  
Meio chato, meio bobo  
É ser meio improvisado,  
Meio certo, meio errado  
É ter só meio juízo  
Sonhar é ser meio doido  
É ser meio trapaceiro  
Trapaceando o real  
Pra ser só meio verdadeiro  
Na vida bom é ser meio  
Não tem graça ser inteiro  
O inteiro, meu povo, o inteiro é o completo  
Não careci acrescentar  
É sem graça, é insosso  
É não ter porque lutar  
Quem é meio é quase inteiro  
E o quase nos faz sonhar”

**(Bráulio Bessa)**

## RESUMO

O Sensoriamento Remoto Orbital (SRO) viabiliza o monitoramento da cobertura do solo a partir de índices de vegetação. A análise de preenchimento de falhas em séries temporais desses índices é geralmente feita com sensores de alta resolução temporal e baixa resolução espacial. Contudo, em regiões semiáridas, a compreensão em escala local e diária dos fenômenos que ocorrem na cobertura do solo, como por exemplo, na vegetação Caatinga, é muito importante devido à sua rápida resposta aos eventos de chuva, à sua heterogeneidade e às múltiplas ações humanas. Portanto, o presente estudo teve como objetivo reconstruir séries de NDVI (Índice de Vegetação por Diferença Normalizada) para uma área de vegetação Caatinga, obtidas pelos sensores TM, ETM+ e OLI, dos satélites Landsat 5, 7 e 8, respectivamente, testando a aplicação de curvas baseadas em funções matemáticas para preenchimento de falhas, definindo entre essas a que apresenta o melhor ajuste para a área de estudo, que está localizada entre os municípios de Sumé e Monteiro, no Cariri paraibano e é representada nesse trabalho por 19 pontos, sendo 4 de Caatinga preservada e 15 que sofreram alguma alteração antrópica. Para a escolha da melhor equação de ajuste foi utilizado o software LAB Fit levando em consideração os parâmetros estatísticos qui-quadrado reduzido ( $\chi^2$ ) e coeficiente de determinação ( $R^2$ ), para essa aplicação foram utilizados 4 pontos da área de estudo onde não houve alteração referente ao período de 1994 a 2017. A função Cauchy de três parâmetros foi escolhida para o ajuste do NDVI e foi testada utilizando dois critérios: status de alteração da cobertura do solo (alterada ou não pela ação antrópica) e regime pluviométrico anual (ano seco ou chuvoso). A função se ajustou bem mesmo após a alteração da cobertura, para a maioria dos pontos analisados (85%), e teve bom desempenho para os anos chuvosos, ou seja, aqueles que apresentaram precipitação anual acima da média para o período analisado (514 mm), ajustando bem em 83% desses anos, obtendo um  $R^2$  médio de 0,82. A função ajustada poderá ser utilizada em áreas que apresentam semelhança em relação ao clima e vegetação presentes nos pontos observados neste trabalho. Esta abordagem pode ser utilizada como uma ferramenta para produzir estimativas de biomassa em escala local e regional, além de viabilizar análises mais sensíveis do comportamento da vegetação no semiárido brasileiro, como o seu ciclo fenológico, sua relação com o sequestro de carbono da atmosfera e o efeito das mudanças climáticas sobre a Caatinga.

**Palavras-chave:** Semiárido; Índice de Vegetação; Cauchy; Preenchimento de falhas.

## ABSTRACT

Orbital Remote Sensing (SRO) enables the monitoring of land cover from vegetation indexes. gap-filling analysis in time series of these indices is generally done with high temporal resolution and low spatial resolution sensors. However, in semi-arid regions, the local and daily scale comprehension of the phenomena that occurs in the land cover, such as Caatinga vegetation, is very important due to its heterogeneity and multiple human actions.

Therefore, the objective of this study was to reconstruct NDVI series (Normalized Difference Vegetation Index) for an area of Caatinga vegetation obtained by the TM, ETM + and OLI sensors of the Landsat 5, 7 and 8 satellites, respectively, by testing the application of curves based on mathematical functions to fill in gaps, defining among them the one that presents the best fit for the study area, which is located between the cities of Sumé and Monteiro, in the Cariri region of Paraíba and is represented in this work by 19 points, being 4 of Caatinga preserved and 15 that have some antropic alteration. In order to choose the best adjustment equation, the LAB Fit software was used, taking into account the reduced chi-square ( $\chi^2$ ) and determination coefficient ( $R^2$ ) parameters. For this application, 4 points of the study area were used, for the period from 1994 to 2017. The three-parameter Cauchy function was chosen for NDVI adjustment and was tested using two criteria: status of land cover change (altered or not by anthropic action and annual rainfall). The function fit well even after the coverage change, for most of the analyzed points (85%) and performed well for the rainy years, that is, those that presented annual precipitation above the average (514 mm) for the analyzed period adjusting well in 83% of these years, obtaining an average  $R^2$  of 0.82. The adjusted function can be used in areas that are similar in relation to the climate and vegetation present in the points observed in this work. This approach can be used as a tool to produce estimates of biomass at local and regional scale, in addition to enabling more sensitive analyzes of vegetation behavior in the Brazilian semi-arid, such as its phenological cycle, its relation with the carbon sequestration of the atmosphere and the effect of climate change on the Caatinga.

**Keywords:** Semiarid; Vegetation Index; Cauchy; Break Filling.

## LISTA DE FIGURAS

Figura 1: Elementos essenciais das técnicas de sensoriamento remoto.....	19
Figura 2: Possíveis ângulos de incidência sobre um alvo.....	19
Figura 3: Curvas de Reflectância para diversos alvos.....	22
Figura 4: Curva de Reflectância típica de uma folha verde.....	26
Figura 5: Série de lançamentos dos satélites Landsat.....	34
Figura 6: Localização geográfica da área de estudo.....	41
Figura 7: Fluxograma da primeira etapa metodológica.....	43
Figura 8: Fluxograma da segunda etapa metodológica.....	45
Figura 9: Fluxograma da terceira etapa metodológica.....	47
Figura 10: Análise da precipitação anual no período de 1994-2017.....	47
Figura 11: Fluxograma da quarta etapa metodológica.....	48
Figura 12 (A e B): Qui-quadrado reduzido ( $\chi^2$ reduzido) e coeficiente de determinação ( $R^2$ ) para as 236 séries de NDVI.....	52
Figura 13 (A e B): Ajuste Cauchy para um ano típico seco (A) e chuvoso (B).....	53-54
Figura 14 (A-F): Ajuste Cauchy para o ponto 33.....	56-58

## LISTA DE TABELAS

Tabela 1: Principais índices de vegetação para análise de características estruturais.....	31-32
Tabela 2: Coordenadas dos pontos da área de estudo e seus status com relação à ação antrópica.....	44
Tabela 3: Valores da banda pixel_qa utilizados como filtro para remoção de nuvens.....	45
Tabela 4: Frequência da função Cauchy para os pontos de Caatinga preservada.....	50
Tabela 5: Ranking dos melhores ajustes encontrados.....	51
Tabela 6: Raiz Quadrada do Erro Médio (RMSE) para as funções analisadas.....	58-59

## LISTA DE SIGLAS

$\rho_\lambda$	-	Refletância da folha
$\chi^2$	-	Qui-quadrado reduzido
$\alpha_\lambda$	-	Absortância da folha
$\tau_\lambda$	-	Transmitância da folha
$i_\lambda$	-	Fluxo radiante incidente
$\mu\text{m}$	-	Micrômetros
AESA	-	Agência Executiva de Gestão das Águas do Estado da Paraíba
AG	-	Assimétrica de Gauss
AVHRR	-	<i>Advanced Very High Resolution Radiometer</i>
CO <sub>2</sub>	-	Molécula de gás carbônico
DJ	-	Dia Juliano
DL	-	Dupla Logística
ERTS	-	<i>Earth Resource Technology Satellite</i>
ETM+	-	<i>Enhanced Thematic Mapper Plus</i>
EVI	-	<i>Enhanced Vegetation Index</i>
GRVI	-	<i>Green-red Vegetation Index</i>
IBGE	-	Instituto Brasileiro de Geografia e Estatística
IV's	-	Índices de vegetação
Km	-	Kilômetro
L	-	Parâmetro de ajuste para o solo
LANDSAT	-	<i>Land Remote Sensing Satellite</i>
LULC	-	<i>Land User and Land Cover</i>
m	-	Metro
MODIS	-	<i>Moderate-Resolution Imaging Spectroradiometer</i>
MSAVI	-	<i>Modified SAVI</i>
MSS	-	<i>Multispectral Scanner</i>
NASA	-	<i>National Aeronautics and Space Administration</i>
NDVI	-	<i>Normalized Difference Vegetation Index</i>
NIR	-	Infravermelho próximo
NOAA	-	<i>National Oceanic and Atmospheric Administration</i>
O <sub>2</sub>	-	Molécula de gás oxigênio
OLI	-	<i>Operational Land Imager</i>
OSAVI	-	<i>Optimized SAVI</i>
PAN	-	Pancromática
R <sup>2</sup>	-	Coefficiente de determinação
$R_B$	-	Reflectância no azul
$R_G$	-	Reflectância no verde
$R_{NIR}$	-	Reflectância no Infravermelho próximo

$R_{RED}$	-	Reflectância no vermelho
RDVI	-	<i>Renormalized Difference Vegetation Index</i>
RED	-	Vermelho
REM	-	Radiação eletromagnética
RMSE	-	<i>Root Mean Square Error</i>
SARVI	-	<i>Soil and Atmospherically Resistant Vegetation Index</i>
SAVI	-	<i>Soil Adjusted difference Vegetation Index</i>
SG	-	Savitzky-Golay
SLC	-	<i>Scan Line Corrector</i>
SR	-	<i>Simple Ratio</i>
SRO	-	Sensoriamento Remoto Orbital
SWIR	-	<i>Short-wavelength infrared</i>
TIRS	-	<i>Thermal Infrared Sensor</i>
TM	-	<i>Thematic Mapper</i>
USGS	-	<i>United States Geological Survey</i>
WRS	-	<i>Worldwide Reference System</i>

## SUMÁRIO

1.	INTRODUÇÃO .....	14
2.	OBJETIVOS .....	16
2.1.	Objetivo geral .....	16
2.2.	Objetivos específicos .....	16
3.	FUNDAMENTAÇÃO TEÓRICA.....	16
3.1.	Bioma Caatinga .....	16
3.2.	Sensoriamento Remoto Orbital (SRO) .....	18
3.2.1.	<i>Comportamento espectral dos alvos</i> .....	21
3.2.2.	<i>Comportamento espectral da vegetação</i> .....	23
3.2.3.	<i>Sensoriamento remoto da vegetação</i> .....	29
3.3.	Índices de Vegetação (IV's) .....	30
3.4.	Programa LANDSAT .....	33
3.4.1.	<i>LANDSAT 5</i> .....	34
3.4.2.	<i>LANDSAT 7</i> .....	35
3.4.3.	<i>LANDSAT 8</i> .....	35
3.5.	Banda de qualidade em produtos de SRO .....	36
3.6.	Séries temporais de dados de SRO.....	37
3.7.	Preenchimento de falhas em séries temporais de NDVI.....	38
4.	METODOLOGIA .....	41
4.1.	Área de estudo .....	41
4.2.	Etapas metodológicas .....	42
4.2.1.	<i>Aquisição e processamento de dados</i> .....	43
4.2.2.	<i>Definição da função de ajuste</i> .....	45
4.2.3.	<i>Aplicação da função de ajuste</i> .....	46
4.2.4.	<i>Validação da função de ajuste</i> .....	48
5.	RESULTADOS E DISCUSSÕES .....	49
5.1.	Obtenção das séries de NDVI limpas de nuvens.....	49
5.2.	Curva de ajuste.....	50
5.3.	Aplicação do ajuste Cauchy .....	51
5.4.	Validação do ajuste.....	58
6.	CONCLUSÕES .....	59
	REFERÊNCIAS BIBLIOGRÁFICAS .....	62
	ANEXOS .....	73

## 1. INTRODUÇÃO

As plantas são fundamentalmente dependentes do seu ambiente físico para crescimento, sobrevivência e reprodução. Para entender seu comportamento, são imprescindíveis ferramentas tanto para quantificação do meio ambiente quanto para o estudo da vegetação e seu funcionamento. Nos últimos anos, houve um reconhecimento cada vez maior de que para a melhoria futura do monitoramento e manejo dos ecossistemas naturais, por exemplo em resposta às mudanças climáticas, necessita-se de uma boa compreensão dos mecanismos subjacentes à resposta da planta. Da mesma forma para o ambiente, a previsão das mudanças climáticas e dos impactos por elas causados, são criticamente dependentes do entendimento do papel da vegetação no controle de mudanças no balanço energético terrestre (JONES; VAUGHAN, 2010).

Dados e registros das mudanças que ocorrem no meio ambiente têm sido obtidos por sensoriamento remoto, pois o frequente registro de imagens por diversos sensores orbitais permite a construção e a análise de séries temporais de dados da vegetação (KUPLICH *et al.*, 2013). A observação e a análise dessas séries podem auxiliar no reconhecimento de padrões e na análise de possíveis alterações desses padrões por causas naturais ou antrópicas (JIA *et al.*, 2014; MARIANO *et al.*, 2018). Nesses estudos, os índices de vegetação (IVs) têm sido bastante utilizados, na literatura podemos encontrar diversos estudos que demonstram isso (HIGGINBOTTOM; SYMEONAKIS, 2014; IBRAHIM *et al.*, 2015; LEROUX *et al.*, 2017; VERBESSELT *et al.*, 2016).

Os IVs nada mais são do que combinações de dados espectrais de duas ou mais bandas espectrais, escolhidas com o objetivo de agrupar e intensificar a relação desses dados com os parâmetros biológicos e físicos da vegetação. Dentre os IVs mais utilizados para verificar esses padrões obtidos por sensoriamento remoto, está o NDVI - Índice de Vegetação por Diferença Normalizada (LOURENÇO *et al.*, 2015).

Como as propriedades de reflectância da vegetação variam sazonalmente em relação a sua fenologia, as séries temporais e espaciais desses índices, como o NDVI, oferecem um mecanismo único para monitorar a dinâmica da vegetação, uma vez que possibilitam o estudo desde escalas macro (ecossistemas) até as microescalas (regiões específicas e áreas de interesse), dependendo do sensor utilizado na análise (PASTOR-GUZMAN; DASHA; ATKINSON, 2018).

Muitas pesquisas têm utilizado séries temporais de índices de vegetação para o monitoramento da vegetação, por diversos sensores a bordo de satélites, como o MODIS

(CAI *et al.*, 2017; SOUZA *et al.*, 2016; KUPLICH *et al.*, 2013), os sensores ETM, ETM+ e OLI do LANDSAT 5, 7 e 8, respectivamente (SILVA *et al.*, 2018; MELAAS *et al.*, 2013) e o AVHRR a bordo do satélite NOAA (ZHANG *et al.*, 2018). No entanto, ao utilizar séries temporais de dados do NDVI, muitas vezes é necessário contornar alguns problemas, como a distribuição temporal dos dados, que está relacionada com o tempo de revisita do satélite, bem como a ausência e/ou a contaminação dos dados, cuja causa está ligada à influência de nuvens e/ou da atmosfera, gerando lacunas na série. Portanto, a análise de preenchimento de falhas é essencial para assegurar uma aplicação apropriada dos produtos NDVI (CAO *et al.*, 2018; JULIEN; SOBRINO, 2019).

Sendo assim, muitos métodos de preenchimento de falhas foram desenvolvidos nos últimos anos, como o filtro 4253H (VELLEMAN, 1980), o filtro Savitzky-Golay (CHEN *et al.*, 2004; JÖNSSON; EKLUNDH, 2004; SAVITZKY; GOLAY, 1964), Função Assimétrica de Gauss (JONSSON; EKLUNDH, 2002; JÖNSSON; EKLUNDH, 2004), filtro Whittaker (ATZBERGER; EILERS, 2011), Função Dupla logística (BECK *et al.*, 2006; ZHANG *et al.*, 2003), Transformada Discreta de Fourier (ATKINSON *et al.*, 2012; BRADLEY *et al.*, 2007; BROOKS *et al.*, 2012; JEGANATHAN; DASH; ATKINSON, 2010; MCCLOY; LUCHT, 2004; ROERINK; MENENTI; VERHOEF, 2000). Contudo, vários estudos compararam a eficiência de alguns desses métodos, mas nenhum consenso claro surgiu sobre qual é o melhor para o preenchimento de falhas em séries temporais de índices de vegetação (LIU *et al.*, 2017; ATKINSON *et al.*, 2012; HIRD; MCDERMID, 2009).

É interessante, portanto, a análise específica da aplicação de ajustes para cada região, uma vez que para regiões com características distintas, como clima, cobertura de nuvens e tipo de vegetação, a resposta de cada filtro pode ser diferente, ajustando bem ou não os dados de NDVI. Uma vez obtida uma série contínua de dados através do ajuste, estudos podem ser realizados para monitoramento da vegetação (fenologia), verificação dos efeitos climáticos sobre a vegetação e a cobertura do solo, bem como verificação de áreas com tendência a desertificação, processo bastante preocupante, principalmente na região semiárida brasileira.

Sendo assim, o objetivo desse trabalho é reconstruir séries de NDVI do Landsat para escala diária, , testando a aplicação de curvas baseadas em funções matemáticas para preenchimento de falhas, , definindo entre essas a que apresenta o melhor ajuste para a área de vegetação Caatinga.

## **2. OBJETIVOS**

### **2.1. Objetivo geral**

Reconstruir séries Landsat de NDVI para escala diária, testando a aplicação de curvas baseadas em funções matemáticas para preenchimento de falhas, definindo entre essas a que apresenta o melhor ajuste para a área de vegetação Caatinga.

### **2.2. Objetivos específicos**

- Obter a melhor equação de ajuste para as séries de NDVI da área de estudo;
- Reconstruir as séries de NDVI em escala diária, verificando o comportamento do ajuste quanto ao status de alteração da cobertura do solo (alterado ou preservado) e aos regimes anuais de precipitação (anos secos e chuvosos);
- Validar o melhor ajuste, comparando-o com funções utilizadas na literatura e verificando a eficiência do mesmo na reconstrução das séries de NDVI.

## **3. FUNDAMENTAÇÃO TEÓRICA**

### **3.1. Bioma Caatinga**

O Brasil possui uma imensa extensão territorial, aproximadamente 8.500.000 km<sup>2</sup>, com diversidade de clima, solos e vegetação. Em toda a extensão do país existem porções com características semelhantes e biodiversidade contínua, que define os chamados “biomas”. Um bioma é entendido como um conjunto de todos os seres vivos em uma região que apresenta uniformidade e uma história comum em sua formação. Existem seis biomas bem definidos no Brasil: Amazônia (49,29%), Cerrado (23,92%), Mata Atlântica (13,04%), Caatinga (9,92%), Pampa (2,07%) e Pantanal (1,76%) (IBGE, 2018).

A Caatinga é um bioma exclusivamente brasileiro. Etimologicamente, o termo Caatinga (Tupi-Guarani) significa floresta branca, devido sua paisagem branqueada, caracterizada pelo aparecimento dos troncos de árvores na estação seca, quando a vegetação perde quase que totalmente sua folhagem. Quase 10% do território nacional é ocupado pela Caatinga, que abrange parte dos estados de Alagoas, Bahia, Ceará, Maranhão, Minas Gerais, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe (IBGE, 2018).

A Caatinga surgiu com a extinção da floresta tropical anteriormente existente na região, ocorrida no final da era glacial, há dez mil anos. Além disso, a Caatinga é heterogênea, sendo muito rica em biodiversidade e espécies endêmicas. A vegetação da caatinga é classificada como savana de estepe e a paisagem é bastante diversificada devido à variação acentuada de precipitação, fertilidade, tipos de solo e topografia (SILVA *et al.*, 2018).

A particularidade da cobertura vegetal da Caatinga permite a classificação da paisagem em dois tipos distintos: agreste (serras agrestes) e sertão (sertão). O primeiro envolve a transição entre a área seca e a Mata Atlântica, que é dominada por árvores arbustivas, com muitos ramos entrelaçados; e o segundo (sertão / sertão) possui vegetação mais rústica (SILVA; CRUZ. 2018).

Na Caatinga, as temperaturas médias anuais são altas (25°-29°C), com alta radiação solar. O clima é semiárido, principalmente decorrente do predomínio de massas de ar estáveis, impulsionadas pelos ventos alísios do Sudeste, que têm sua origem na ação anticiclone do Atlântico Sul, conseqüentemente, há uma baixa taxa de umidade relativa e um potencial de evapotranspiração muito alto. O solo que é derivado de diferentes tipos de rocha ainda é raso e pedregoso. As secas são cíclicas e prolongadas. A estação chuvosa é curta, começando no início do ano e com chuvas mais baixas e irregulares. A ocorrência de fenômenos catastróficos, como secas e inundações, é muito comum (SILVA *et al.*, 2018).

A agricultura é a principal atividade econômica realizada na Caatinga. Alguns projetos de irrigação para agricultura são desenvolvidos nos vales do São Francisco e no Rio Parnaíba, que são os principais rios da região (SILVA *et al.*, 2016). A região tem problemas sociais, como baixos níveis de renda e escolaridade e alta taxa de mortalidade infantil.

## REFERENCIA

No semiárido, a vegetação é composta prioritariamente por arbustos que perdem as folhas nos meses mais secos ou por pastagens que secam na época de estiagem, essas são características da Caatinga presente na região Nordeste do Brasil. A vegetação da Caatinga é muito sensível às variações climáticas, principalmente com relação as alterações de disponibilidade hídrica, o que dificulta as análises de padrões, por necessitar de um período longo de dados, o qual possa representar fielmente o comportamento da Caatinga às mudanças climáticas e às ações antrópicas (ALVES, 2012).

No Bioma Caatinga, as ações antrópicas ao longo dos anos vêm modificando a paisagem, intensificando o processo de substituição das áreas naturais por diversos tipos de uso do solo e reduzindo áreas florestadas. Apesar de sua grande riqueza em biodiversidade,

a Caatinga é o bioma brasileiro mais negligenciado. O uso indiscriminado do solo e dos recursos naturais, durante o processo de ocupação e exploração, degradou a Caatinga. A singularidade, o uso insustentável, a riqueza particular e a pequena extensão expressam a necessidade de estudos que busquem preservar o bioma (MATSUSHITA *et al.*, 2006; LEAL *et al.*, 2005).

Diversos fatores estão diretamente ligados a este processo, uma dessas causas é a exploração intensa de áreas com agricultura familiar e pecuária, muito comum na região semiárida do nordeste brasileiro. A maior exposição do solo faz com que os processos erosivos se intensifiquem, ocorrendo também perda da biodiversidade (COELHO *et al.*, 2014; VANZELA *et al.*, 2010).

O monitoramento do uso e da cobertura do solo (*LULC*, sigla em inglês), através de informações espaço-temporais detalhadas das modificações ocorridas na paisagem, é a principal ferramenta para o conhecimento das capacidades e limitações de uma região (COELHO *et al.*, 2014). Ressalta-se, no entanto, a necessidade de uma atualização constante desses registros, para que padrões possam ser detectados (LAGO *et al.*, 2012). Muitos estudos em todo o mundo têm realizado esse monitoramento através do sensoriamento remoto em escalas multitemporais, como os trabalhos de Schulz *et al.* (2017), Lu *et al.* (2016), Beuchle (2015) e Mendoza (2011).

### **3.2. Sensoriamento Remoto Orbital (SRO)**

O sensoriamento remoto pode ser definido, segundo Novo (2008), como sendo a utilização simultânea de sensores, equipamentos de transmissão de dados a bordo de aeronaves, espaçonaves, ou outras plataformas, cujo objetivo é estudar eventos, fenômenos e processos que ocorrem na superfície da Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que compõem a superfície terrestre em suas mais diversas manifestações.

Desta forma, as técnicas de sensoriamento remoto têm como base quatro elementos que estão descritos na Figura 1. A radiação eletromagnética (REM) é o elemento de ligação entre todos os demais que se posicionam nos vértices, que são: fonte de REM, sensor e alvo. A fonte de REM varia de acordo com a aplicação. O Sol é a principal fonte de REM para sensores ópticos, já para sensores termais e de microondas passivos, a Terra é a principal fonte de REM. O alvo é o elemento que se pretende extrair informação e o sensor é o instrumento que coleta a REM refletida ou emitida pelo alvo (ANGELIS, 2011).

**Figura 1** – Elementos essenciais das técnicas de sensoriamento remoto.



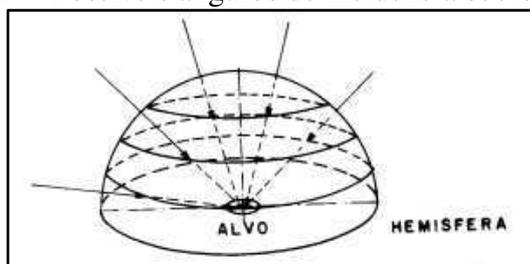
Fonte: Angelis (2011).

As técnicas de SRO são utilizadas com o intuito de identificar determinadas características dos alvos em análise sem a necessidade de contato direto com os mesmos. É assim que os sensores acoplados nos satélites que orbitam o planeta Terra captam informações espectrais da superfície, registrando os níveis de radiação eletromagnética refletida e/ou emitida pelos alvos (JENSEN, 2009).

Para que se possa compreender melhor como se viabiliza a aplicação das técnicas de SRO no estudo dos recursos naturais, é necessário o entendimento de pelo menos quatro parâmetros radiométricos. O primeiro deles, refere-se à irradiância. Em termos simples, a irradiância representa a intensidade do fluxo radiante que atinge uma determinada superfície e que é proveniente de todas as direções (NOVO; PONZONI, 2001).

A Figura 2 apresenta o aspecto geométrico formado pelos raios que são emitidos pela fonte. Vale salientar que neste fluxo radiante estão contidos todos os diversos comprimentos de onda que são radiados pela fonte, segundo suas próprias características.

**Figura 2** – Possíveis ângulos de incidência sobre um alvo.



Fonte: Novo e Ponzoni (2001).

Logo que um determinado fluxo radiante atinge uma superfície, ele sofre três fenômenos: reflexão, transmissão e absorção. Estes fenômenos dependem das características

físico-químicas do próprio alvo, que definem as intensidades de reflexão, transmissão e absorção da REM em cada comprimento de onda incidente no objeto. Verificando então somente a parte refletida pelo alvo, um novo fluxo será originado em sentido contrário ao incidente, mas nas mesmas direções. A intensidade deste fluxo pode ser quantificada e é conhecida como exitância. Parte deste fluxo refletido pelo objeto pode ser coletado por um sensor localizado remotamente. O termo “parte” refere-se a dois aspectos: um de ordem geométrica e outro de ordem espectral. O de ordem geométrica refere-se ao fato de que não há instrumentos capazes de registrar a exitância, uma vez que seria necessário o desenvolvimento de um sensor que envolvesse todo o alvo, o que comprometeria a incidência da REM (NOVO; PONZONI, 2001).

Evidentemente, poderiam ser desenvolvidos métodos que permitissem sua estimativa, mas outra solução foi adotada. Todo sensor possui uma abertura pela qual a REM refletida ou emitida pelos objetos passa em direção ao chamado “detetor”, que é o elemento que realmente lê a REM. Essa abertura possui dimensões variáveis e dependentes das características tecnológicas do instrumento ou da própria natureza das operações de coleta de dados. Sendo assim, entre esta abertura e o ponto da superfície do objeto passa a ser definido um cone por onde trafega a REM. Esse cone é denominado de ângulo sólido. Somente a REM que estiver contida neste ângulo sólido será captada pelo detetor, mas ao mesmo tempo, o sensor não observa somente um ponto na superfície e sim uma determinada área desta superfície, a qual é constituída por infinitos pontos. Assim, o que realmente é medido pelo sensor é a intensidade de todos os infinitos fluxos contidos nos ângulos sólidos dos pontos da área da qual ele é capaz de observar. Esta intensidade é denominada de radiância (MOREIRA, 2007).

A radiância é, portanto, a intensidade do fluxo radiante por unidade de ângulo sólido e seu conceito pode ser comparado ao conceito de brilho, ou seja, um alvo é considerado mais brilhante quanto maior for sua radiância medida. O aspecto espectral refere-se ao fato de que a composição espectral do fluxo que deixa a superfície sofre alterações que são dependentes das suas características físico-químicas. Assim, a radiância medida por um sensor pode ser determinada para um intervalo específico de comprimentos de onda (região ou banda espectral). Os sensores remotos são dispositivos capazes de detectar a energia eletromagnética (em determinadas faixas do espectro eletromagnético) proveniente de um objeto, transformá-las em um sinal elétrico e registrá-las, de tal forma que este possa ser armazenado ou transmitido em tempo real para posteriormente ser convertido em

informações que descrevem as feições dos objetos que compõem a superfície terrestre (MORAES, 2002).

Existem três aspectos importantes que devem ser levados em consideração para estudos de identificação de padrões a partir de dados de SRO, quais sejam: o aspecto temporal, o aspecto espacial e o aspecto espectral. O domínio temporal, refere-se ao período de tempo compreendido entre duas coletas de dados sobre uma mesma superfície do terreno. Este domínio é expresso pela resolução temporal da plataforma que sustenta o sensor. Diz-se que um sensor possui maiores resoluções temporais quanto menores forem os períodos de tempo entre coletas de dados (MOREIRA, 2007).

O aspecto espacial é expresso pela resolução espacial do sensor, a qual é definida como a menor área da qual o sensor é capaz de registrar a REM. O domínio espectral refere-se à largura da faixa espectral que este mesmo sensor é sensível. Faixas mais largas conferem uma resolução espectral menor ao sensor. Contrariamente, elementos de resolução espacial menores conferem aos sensores, maiores resoluções espaciais (NOVO; PONZONI, 2001).

Para que se conheça as propriedades intrínsecas dos objetos em termos de sua interação com a REM, é necessário o conhecimento de um conceito importante, que é o da Reflectância. A assinatura espectral de um alvo, ou simplesmente sua reflectância, é a intensidade relativa com a qual um alvo (uma folha, por exemplo) reflete ou emite a radiação eletromagnética incidente sobre ela nos diferentes comprimentos de onda do espectro eletromagnético. Sendo assim, a reflectância expressa as propriedades intrínsecas dos objetos em refletir a REM que incide sobre eles. Ela é expressa em percentagem, possuindo então um caráter relativo. É através da reflectância que são estudadas as características intrínsecas dos objetos em refletir a REM incidente, pois ela é dependente das suas propriedades físico-químicas (NOVO; PONZONI, 2001).

### ***3.2.1. Comportamento espectral dos alvos***

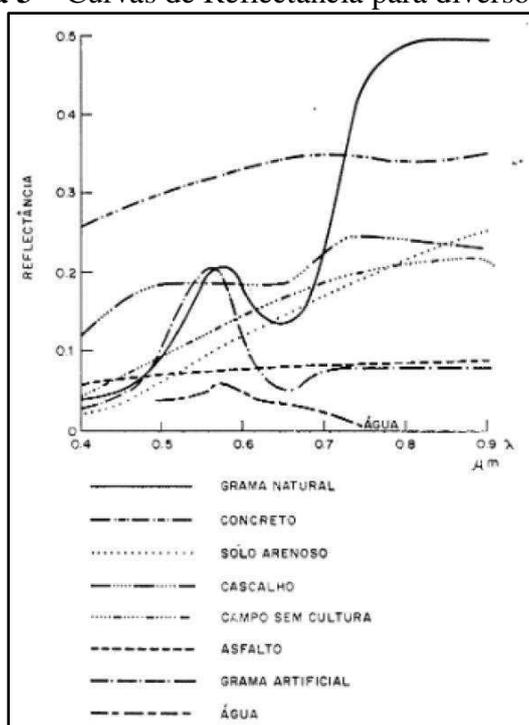
O termo comportamento espectral de alvos tem sido atribuído pelos profissionais que atuam na aplicação do SRO no estudo dos recursos naturais, como o estudo da reflectância espectral destes recursos, quer sejam: vegetação, solos, minerais e rochas, água, etc. Em termos gerais, estudar como um objeto se comporta espectralmente, deve contemplar os três fenômenos já mencionados que ocorrem após a incidência da REM sobre um dado objeto: reflexão, transmissão e absorção. Assim, o comportamento espectral de um alvo só é

plenamente compreendido quando são estudadas suas propriedades de refletir, transmitir e absorver a REM (NOVO; PONZONI, 2001).

Contudo, serão enfatizadas aqui as propriedades de reflexão dos alvos (recursos naturais), uma vez que a maioria dos sensores atualmente disponíveis para o estudo dos recursos naturais utilizam a REM refletida por eles. A caracterização de como e de quanto um objeto reflete a REM pode ser feita em diversos níveis e formas. Nos primeiros, estão incluídos os chamados níveis de aquisição de dados, os quais podem ser de laboratório, campo, aéreo e orbital.

Em cada um destes níveis podem ser adotadas variadas formas, as quais incluem as chamadas geometrias de iluminação e de visada. A primeira refere-se ao posicionamento espacial da fonte de REM em relação ao objeto, enquanto que a segunda se refere ao posicionamento espacial do sensor. Os níveis e as formas condicionam as caracterizações, tornando seus resultados específicos para as situações nas quais foram concebidos. Este fato torna imprescindível que em qualquer caracterização da reflectância espectral de um objeto, sejam bem descritas as condições de iluminação e visada adotadas, tanto no que se refere aos domínios espacial, espectral, temporal e ainda das suas geometrias. A Figura 3 ilustra as curvas de reflectância de alguns recursos naturais e artefatos construídos pelo ser humano (NOVO, PONZONI, 2001).

**Figura 3** – Curvas de Reflectância para diversos alvos.



Fonte: Novo e Ponzoni (2001).

Como pode ser observado na Figura 3, na região do visível (0,4 a 0,7  $\mu\text{m}$ ) a maioria das curvas dos alvos apresentados encontram-se muito próximas entre si, em contraste com um maior distanciamento entre elas na região espectral (infravermelho próximo, de 0,7 a 0,9  $\mu\text{m}$ ). Isto indica que na região do visível, os alvos apresentam-se “parecidos”, enquanto que na região do infravermelho eles podem ser mais facilmente individualizados. Nos pontos de intersecção entre as curvas, os quais ocorrem com alguma frequência em pontos específicos do espectro, diz-se que os alvos apresentam a mesma reflectância, ou seja, eles assumem uma mesma “aparência” quando observados mediante alguma técnica de SRO.

Estas curvas de reflectância são curvas médias que ilustram as formas típicas dos alvos apresentados refletirem a REM sobre eles incidente. Servem somente de base para formar uma ideia da reflexão destes alvos, não sendo possível sua generalização, uma vez que também não foram fornecidas informações adicionais sobre as condições (geométricas e dos próprios alvos) adotadas quando foram geradas. Esta forma típica é geralmente referenciada com o termo assinatura espectral. Através da análise de curvas como estas apresentadas na Figura 3, pode ser prevista a aparência de alvos em produtos de SRO, tais como imagens orbitais e/ou fotografias aéreas. Esta aparência é expressa pela tonalidade (clara ou escura) assumida pelos alvos e dependendo do tipo de produto, ela ainda pode ser expressa pela cor e pela textura. O conhecimento sobre o comportamento espectral de alvos é, portanto, fundamental para a extração de informações a partir de produtos de SRO, quer sejam fotografias, ou imagens (NOVO; PONZONI, 2001).

### ***3.2.2. Comportamento espectral da vegetação***

Estudos da cobertura vegetal podem envolver quatro diferentes níveis de coleta de dados: laboratório, campo, aeronave e orbital. Em laboratório, comumente são consideradas as folhas, partes de plantas ou até alguns arranjos de plantas, dos quais são coletados dados radiométricos com o objetivo de caracterizar espectralmente, aspectos relacionados ao processo de interação entre a REM e a vegetação. Em campo, os dados podem ser coletados diretamente das folhas ou através de dispositivos como plataformas (móveis ou fixas), teleféricos, etc; que permitem a inserção dos sensores imediatamente acima dos dosséis vegetais segundo as mais diferentes disposições (NOVO; PONZONI, 2001).

Segundo Moreira (2007), na coleta de dados em aeronave, estão incluídas as máquinas fotográficas, os radiômetros e os sensores eletro-ópticos, os drones, assim como no nível orbital. A aplicação de técnicas de SRO para estudos da vegetação está

fundamentada em verificar o comportamento, ou seja, a “aparência” da mesma nos produtos obtidos pelo sensoriamento remoto, verificando as complexas interações entre a vegetação e o meio ambiente. Isso é possível a partir dos fluxos de radiação emitidos pelos alvos e captados pelos sensores dos satélites.

Ainda segundo Moreira (2007), um fluxo de radiação incidente sobre qualquer um dos elementos de um dossel vegetal (folhas, galhos, frutos, flores, etc.) estará sujeito a dois processos: espalhamento e absorção. O processo de espalhamento, pode ser dividido em dois sub-processos: reflexão e transmissão através do elemento. O destino do fluxo radiante incidente sobre um destes elementos é então dependente das características do fluxo (comprimentos de onda, ângulo de incidência e polarização) e das características físico-químicas destes mesmos elementos.

De todos os elementos constituintes da vegetação, a folha constitui o principal deles quando se considera o processo de interação descrito. Para um melhor entendimento das características de reflectância da REM incidente sobre uma folha é necessário o conhecimento de sua composição química, principalmente tipo e quantidade de pigmentos fotossintetizantes, e de sua morfologia interna (distribuição e quantidade de tecidos, espaços intercelulares, etc).

Uma folha típica é constituída de três tecidos básicos que são: epiderme, mesófilo fotossintético e tecido vascular. A folha é então coberta por uma camada de células protetoras epidérmicas, na qual muitas vezes desenvolve-se uma fina e relativamente impermeável superfície externa. Abaixo da epiderme encontra-se o mesófilo fotossintético, o qual por sua vez é subdividido numa camada ou em camadas de células paliádicas alongadas, arranjadas perpendicularmente à superfície da folha, que formam o parênquima (MOREIRA, 2007). As células do parênquima são ocupadas por seiva e protoplasma. Esparsos através do mesófilo estão os espaços intercelulares cheios de ar, os quais se abrem para fora através dos estômatos. Esta rede de passagens de ar constitui a via de acesso pela qual o CO<sub>2</sub> alcança as células fotossintéticas e o O<sub>2</sub> liberado na fotossíntese retorna à atmosfera externa. Uma terceira característica estrutural da folha é o tecido vascular. A rede de tecidos do sistema vascular não serve somente para suprir a folha com água e nutrientes do solo, mas também constitui a passagem pela qual fluem os produtos da fotossíntese que são produzidos na folha, para as demais partes da planta. As estruturas das células que compõem os três tecidos das folhas são muito variáveis, dependendo da espécie e das condições ambientais (JENSEN, 2009).

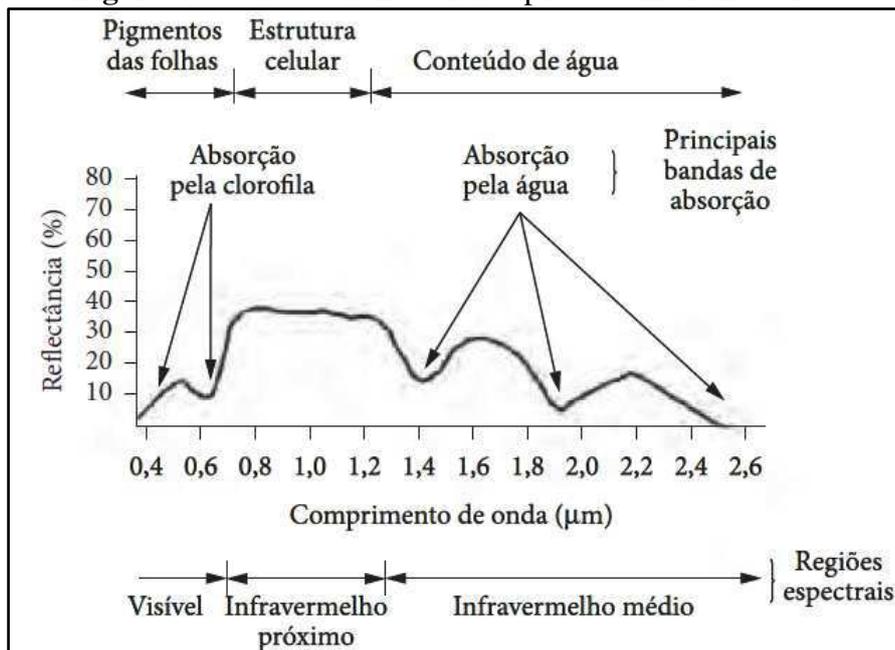
O comportamento espectral de uma folha é função de sua composição, morfologia e estrutura interna. Desde que as características da folha sejam geneticamente controladas, existirão, portanto, diferenças no comportamento espectral entre grupos geneticamente distintos. Levando em consideração o conceito da reflectância interna numa folha e os conhecimentos do espectro de absorção da clorofila, Willstatter e Stoll (1918), desenvolveram uma teoria sobre a trajetória da REM dentro de uma folha, a qual é válida até hoje.

Os referidos autores basearam sua teoria na estrutura interna das folhas e na reflectância potencial das superfícies. Segundo eles, a trajetória da REM se daria ao longo de vários meios, sendo estes compostos pela água, ar, membranas celulares, etc. Um mesmo feixe de radiação poderia passar, por exemplo, através de uma camada de água, que possui um índice de refração de 1,33, e em seguida atravessar um espaço preenchido com ar, que possui um índice de refração igual a 1.

Além desta variação nos índices de refração dos diversos meios a serem atravessados, foi considerado que as células dos tecidos foliares, principalmente do mesófilo esponjoso, possuem uma estrutura irregular, sendo orientada espacialmente sob diversos ângulos. Willstatter e Stoll (1918) imaginaram as possíveis trajetórias da REM dentro de uma folha. Uma pequena quantidade de luz é refletida das células da camada superficial. A maior parte é transmitida para o mesófilo esponjoso, onde os raios incidem frequentemente nas paredes celulares, sendo refletidos se os ângulos de incidência forem suficientemente grandes. Esta reflexão múltipla é um processo aleatório no qual os raios mudam de direção dentro da folha. Devido ao grande número de paredes celulares dentro da folha, alguns raios são refletidos de volta, enquanto outros são transmitidos através da folha. A espessura da folha é fator importante no caminho da REM, já que geralmente a transmitância é maior do que a reflectância para folhas finas, e o inverso acontece com folhas grossas.

A curva de reflectância característica de uma folha verde sadia é mostrada na Figura 4. Os comprimentos de onda relativos ao ultravioleta não foram considerados, porque uma grande quantidade dessa energia é absorvida pela atmosfera e a vegetação não a utiliza.

A análise da Figura 4 indica que a região compreendida entre 400 nm e 2600 nm pode ser dividida em três áreas: região do visível (400 nm a 700 nm), região do infravermelho próximo (700 nm a 1300 nm) e a região do infravermelho médio (1300 nm a 2600 nm).

**Figura 4** – Curva de reflectância típica de uma folha verde.

Fonte: Moreira (2007).

Os principais aspectos relacionados ao comportamento espectral da folha, em cada uma destas regiões são:

- Região do visível: nesta região os pigmentos existentes nas folhas dominam a reflectância espectral. Estes pigmentos, geralmente encontrados nos cloroplastos são: clorofila (65%), carotenos (6%), e xantofilas (29%). Os valores percentuais destes pigmentos podem variar grandemente de espécie para espécie. A energia radiante interage com a estrutura foliar por absorção e por espalhamento. A energia é absorvida seletivamente pela clorofila e é convertida em calor ou fluorescência, e também convertida fotoquimicamente em energia estocada na forma de componentes orgânicos através da fotossíntese (JENSEN, 2009).
- Região do infravermelho próximo: nesta região existe uma absorção pequena da REM e considerável espalhamento interno na folha. A absorção da água é geralmente baixa e a reflectância espectral é quase constante. Gates *et al.* (1965) determinou que a reflectância espectral de folhas nessa região do espectro eletromagnético é o resultado da interação da energia incidente com a estrutura do mesófilo. Fatores externos à folha, como disponibilidade de água por exemplo, podem causar alterações na relação água-ar no mesófilo, podendo alterar a reflectância de uma folha nesta região. De maneira geral, quanto mais lacunosa for a estrutura interna foliar, maior será o espalhamento interno da radiação incidente, e conseqüentemente, maior será também a reflectância.

- Região do infravermelho médio: a absorção devido à água líquida predomina na reflectância espectral das folhas na região do infravermelho próximo. Considerando a água líquida, esta apresenta na região em torno de 2000 nm, uma reflectância geralmente pequena, sendo menor do que 10% para um ângulo de incidência de 65° e menor do que 5% para um ângulo de incidência de 20°. A água absorve consideravelmente a REM incidente na região espectral compreendida entre 1300 nm a 2000 nm. Em termos mais pontuais, a absorção da água se dá em 1100 nm, 1450 nm, 1950 nm e 2700 nm (JENSEN, 2009).

O balanço de energia para quantificar essa reflectância baseia-se na seguinte formulação:

$$\rho_{\lambda} = i_{\lambda} - (\alpha_{\lambda} + \tau_{\lambda}) \quad (1)$$

Onde:

- $\rho_{\lambda}$ : Reflectância da folha;
- $i_{\lambda}$ : Fluxo radiante incidente;
- $\alpha_{\lambda}$ : Absortância da folha;
- $\tau_{\lambda}$ : Transmitância da folha.

A visualização da cor verde das folhas saudáveis de uma planta se deve ao fato que a clorofila (a e b) absorvem com maior eficiência as porções azul e vermelha do espectro visível. Portanto, a menor absorção da porção verde faz com que a planta, conseqüentemente, reflita mais na porção verde do espectro e por isso, a cor característica das plantas é o verde.

As duas regiões espectrais ótimas para observar as características de absorção da clorofila de uma folha são localizadas entre 0,45-0,52  $\mu\text{m}$  e entre 0,63 – 0,69  $\mu\text{m}$ . Carter (1993) sugere que o aumento da reflectância no visível é a mais consistente resposta da reflectância foliar ao estresse. A reflectância no infravermelho é um indicador consistente do estresse hídrico, somente quando ocorre severa desidratação foliar.

As regiões espectrais da parte visível do espectro que são mais sensíveis à estresse hídrico, localizam-se nos intervalos de 535 a 640 nm e de 685 a 700 nm. O sensoriamento remoto nestes intervalos espectralmente estreitos, pode fornecer um meio muito importante para detectar estresses não somente para folhas individuais como também para plantas inteiras e até mesmo para dosséis vegetais densos. Se as plantas absorvessem a energia incidente no infravermelho próximo, com a mesma eficiência do visível, isso poderia levar a um superaquecimento e a danos irreversíveis às suas proteínas. Assim, as plantas desenvolveram uma adaptação, de tal forma que elas não usam esta grande quantidade de energia do infravermelho próximo, simplesmente refletindo-a ou transmitindo-a para as

camadas inferiores de folhas ou para o solo (JENSEN, 2009).

Numa folha verde a camada correspondente ao mesófilo esponjoso controla a quantidade de energia do infravermelho próximo que será refletida. A região espectral ótima para verificar o estresse hídrico em plantas no infravermelho próximo é indicada como sendo entre 0,74 – 0,90  $\mu\text{m}$ . Quanto maior o número de camadas de folhas num dossel maduro e sadio, teoricamente maior a reflectância no infravermelho próximo (BRANDÃO *et al.*, 2008).

A reflectância no infravermelho próximo é diretamente proporcional ao crescimento da biomassa, enquanto a reflectância no vermelho (visível) é inversamente proporcional ao desenvolvimento do dossel das plantas. Uma cultura planejada adequadamente inicia-se como solo exposto e úmido e termina com o solo exposto e seco (após a colheita). No início, tanto a reflectância no infravermelho próximo quanto no visível (vermelho) são baixas, à medida que a vegetação se desenvolve, a reflectância no infravermelho próximo aumenta até atingir seu valor máximo. Quando o dossel está completamente fechado, conseqüentemente, a reflectância no visível (vermelho) atinge seu valor mínimo. O processo inverso acontece quando ocorre a colheita, porém o solo retorna para uma condição mais seca (menos úmida) do que aquela inicial (JENSEN, 2009).

Existem diversos estudos que relacionam a reflectância no vermelho e no infravermelho próximo com a biomassa. Foi comprovado, que associações através de combinações lineares dos dois valores de reflectância, apresentam respostas mais consistentes do estado da biomassa, do que a avaliação isolada de cada uma das reflectâncias. Esse conjunto de combinações lineares deram origem aos índices de vegetação (SHIRATSUCHI *et al.*, 2014).

Já o estresse hídrico da vegetação pode ser avaliado a partir da reflectância da folha no infravermelho médio. A água líquida presente na atmosfera apresenta maior absorvância nos comprimentos de onda: 0,97, 1,19, 1,45, 1,94, 2,27  $\mu\text{m}$ , entre o infravermelho próximo e o médio. Entretanto, a reflectância no infravermelho médio nos comprimentos de onda adjacentes àqueles de maior absorvância da água, é indicadora da quantidade de água presente na planta (JENSEN, 2009).

No infravermelho médio, quando a vegetação apresenta turgidez (quantidade de água) alta, sua reflectância é baixa e apresenta alta absorvância. Logo, no caso em que a turgidez na planta estiver baixa, a reflectância no infravermelho médio será maior, indicando estresse hídrico. Contudo, variações significativas nas curvas de reflectância no visível (0,4-0,7  $\mu\text{m}$ ) só são perceptíveis quando a umidade relativa da planta cai abaixo de 50%. Portanto, para

queda de umidade superior a 50%, qualquer uma porção do visível, do infravermelho próximo e do infravermelho médio pode prover alguma informação útil da reflectância espectral (JENSEN, 2009).

### 3.2.3. *Sensoriamento Remoto da Vegetação*

Quando o alvo em estudo é a vegetação, as análises tornam-se relativamente mais complexas. Segundo Houborg (2015), estudos sobre as aplicações do sensoriamento remoto para a caracterização das copas de vegetação começaram a acelerar no final da década de 1960.

Os sistemas de sensoriamento remoto ópticos (exceto radares) são geralmente limitados a funcionarem em intervalos espectrais de 0,3-1,3  $\mu\text{m}$  ; 1,5-1,8  $\mu\text{m}$ ; 2,0-2,6  $\mu\text{m}$ , devido a fortes bandas de absorção pela água atmosférica em 1,45; 1,94 e 2,7  $\mu\text{m}$ . Felizmente, existe uma forte sensibilidade à reflectância da água nas porções do espectro adjacentes a esses comprimentos em 1,5-1,8  $\mu\text{m}$  e em 2,0-2,6  $\mu\text{m}$ .

Por isso os satélites Landsat 5 e Landsat 7 possuem sensores que captam a reflectância nos dois intervalos citados, sendo 1,5-1,75  $\mu\text{m}$  (Banda 5) e 2,08-2,35  $\mu\text{m}$  (Banda 7). (USGS, 2018). Já foi mostrado de maneira consistente que a banda do infravermelho médio (1,5 - 1,75  $\mu\text{m}$ ) é sensível ao conteúdo de umidade do dossel. Já foi comprovado por Spanner *et al.*, (1990) que essa banda, bem como os índices de vegetação em que ela é usada, estavam correlacionadas com estresse de água em dosséis de florestas coníferas.

O sensoriamento remoto no infravermelho termal e nas microondas passivas também têm fornecido valiosas informações sobre evapotranspiração de dosséis vegetais. A aplicação mais prática das informações sobre umidade das plantas é a avaliação regional das condições de umidade das culturas agrícolas com objetivos de planejamento de irrigação, de avaliação de estresses e de modelagem de produtividade (tanto agrícola quanto de pastagens ou para manejo de florestas). Infelizmente, os dosséis das plantas não refletem os raios solares incidentes de maneira igualitária em todas as direções, dependendo dos ângulos de incidência e azimutal solar e da geometria de visada do sensor, além de outros fatores que interferem nessa reflexão (JENSEN, 2009).

Uma cultura que possua plantas cujos dosséis cubram completamente a superfície do solo, não será possível o sensor capturar as reflexões do solo nessa área. Porém, se o inverso ocorre e existem aberturas entre os dosséis, então a imagem captada pelo sensor irá possuir pixels híbridos ou misturados, já que porções do solo também irão refletir, sendo passíveis

de captação pelo sensor, misturando-se com a reflexão das plantas. É possível separar a contribuição espectral das coberturas individuais, porém isto requer considerável conhecimento em processamento de imagens.

Todos esses fatores relacionados com a vegetação podem ter significativo impacto na reflexão da radiação incidente em direção ao sistema sensor. Portanto, é importante manter constantes tantos fatores quanto possíveis, quando se busca extrair informações biofísicas, tais como, a produtividade primária ou a biomassa via dados de sensores remotos. Mesmo assim, a variação dos ângulos da radiação solar e do sensor podem introduzir efeitos tão marcantes que podem tornar impossível a comparação entre medições de reflectância espectral de determinado momento com outras obtidas em outro momento. Felizmente, se conhecemos bem as características do dossel vegetal em estudo e obtemos informações sobre as características de reflectância bidirecional do ângulo de incidência solar e da geometria de visada do sensor, torna-se possível calibrar os dados de sensoriamento remoto para a extração de informações biofísicas úteis, sendo possível identificar padrões nas variáveis em análise (MOREIRA, 2007).

### **3.3. Índices de Vegetação (IVs)**

Segundo Jensen (2009), os índices de vegetação são medidas radiométricas adimensionais, cujo objetivo é indicar a abundância relativa e a atividade da vegetação verde. Ainda de acordo com Jensen (2009), um índice ideal de vegetação, deve:

- Maximizar a sensibilidade a parâmetros biofísicos da vegetação, preferencialmente de forma linear, de maneira que esta sensibilidade seja fidedigna para uma grande amplitude de condições da vegetação e para facilitar a validação e calibração do índice;
- Normalizar ou modelar os efeitos externos, tais como: ângulo solar, ângulo de visada do sensor, e as interferências atmosféricas, de forma a possibilitar comparações espaciais e temporais;
- Normalizar os efeitos internos, tais como: as variações do substrato abaixo do dossel, incluindo topografia, solos e diferenças quanto a vegetação senescente ou a presença de ramos lenhosos.

Em diversos estudos sobre os recursos naturais, os índices de vegetação são parâmetros fundamentais, pois possibilitam quantificar e qualificar a biomassa e fornecer informações importantes a respeito do ciclo de crescimento e senescência da vegetação, ou

seja, o entendimento de sua fenologia. Estes índices nada mais são do que combinações lineares das reflectâncias em diferentes bandas do espectro, especificamente as bandas do vermelho (RED) e do infravermelho próximo (NIR), por serem mais sensíveis as respostas da vegetação (SOUZA, 2016; BARBOSA; KUMAR, 2016; WORKIE; DEBELLA, 2018).

Inúmeros IVs já foram desenvolvidos para diferentes finalidades. Estudos em todo o mundo usam as características de absorção associadas com constituintes bioquímicos para avaliar diferentes tipos de vegetação. Assim, diferentes índices são utilizados no levantamento da biomassa vegetal e são otimizados para avaliar um processo de interesse (BRANDÃO *et al.*, 2008).

Sendo assim, os IVs podem ser divididos em índices sensíveis à concentração do pigmento (clorofila) e índices estruturais, que podem ou não sofrer a influência das propriedades óticas do solo (HABOUDANE *et al.*, 2004; BRANDÃO *et al.*, 2008). A Tabela 1 apresenta alguns dos índices de vegetação mais utilizados.

**Tabela 1** – Principais índices de vegetação para análise de características estruturais.

ÍNDICE	EQUAÇÃO	REFERÊNCIA
SR ( <i>Simple Ratio</i> )	$SR = R_{NIR}/R_R$	Birth; McVey (1968)
NDVI ( <i>Normalized Difference Vegetation Index</i> )	$NDVI = (R_{NIR} - R_R) / (R_{NIR} + R_R)$	Rouse <i>et al.</i> (1974)
GRVI ( <i>Green-Red Vegetation Index</i> )	$GRVI = (R_G - R_R) / (R_G + R_R)$	Tucker (1979)
SAVI ( <i>Soil Adjusted Difference Vegetation Index</i> )	$SAVI = (1 + L)(R_{NIR} - R_R) / (R_{NIR} + R_R + L)$	Huete (1988)
RDVI ( <i>Renormalized Difference Vegetation Index</i> )	$RDVI = \sqrt{(R_{NIR} - R_R) / (R_{NIR} + R_R)}$	Roujea; Breon (1995)

$$\begin{array}{l} \text{EVI} \\ \text{(Enhanced} \\ \text{Vegetation} \\ \text{Index)} \end{array} \quad \text{EVI} = \frac{2,5 (R_{\text{NIR}} - R_{\text{R}})}{(1 + R_{\text{NIR}} + 6R_{\text{R}} - 7,5R_{\text{B}})} \quad \text{Huete et al. (1997)}$$

---

Fonte: Adaptado de SHIRATSUCHI *et al.* (2014).

Tucker (1979) estudou diferentes combinações lineares das bandas do verde, vermelho e infravermelho próximo para monitorar propriedades como a biomassa, conteúdo de água na folha e conteúdo de clorofila. Além disso, validou o NDVI que foi desenvolvido por Rouse *et al.* (1973). O NDVI é um IV estrutural, muito utilizado para monitoramento agrícola, devido sua forte correlação linear com o crescimento das culturas. Além disso, a razão simples entre o NIR e o RED apresenta uma alta correlação com o desenvolvimento das plantas e com seus estágios de crescimento, sendo esse um dos primeiros IVs estudados. (BIRTH; MCVEY, 1968). Segundo Jensen (2009), pesquisas têm apontado, desde metade do século passado, que existe uma relação direta entre o efeito verificado no NIR e as variações da biomassa. Em contrapartida, tem sido notado que a resposta no visível, especificamente no RED, ocorre de maneira inversa em relação às variações da biomassa da vegetação. Sendo assim, quanto maior for o verdor da vegetação (nível alto de atividade fotossintética) maior será o valor da reflectância no NIR e menor será no RED. A medida que o nível de atividade fotossintetizante diminui, os papéis se invertem e a planta passa a refletir muito no RED e pouco no NIR. Portanto, combinações lineares que envolvam essas duas faixas de comprimentos de onda, podem representar muito bem as condições da vegetação e sua relação com os ciclos hidrológicos, é o que ocorre com o NDVI.

Muitas pesquisas têm utilizado séries temporais de índices de vegetação para o monitoramento da vegetação, por diversos sensores a bordo de satélites, como o MODIS-*Moderate Resolution Image Spectroradiometer* (CAI *et al.*, 2017; SOUZA *et al.*, 2016; KUPLICH *et al.*, 2013), os sensores TM, ETM+ e OLI dos satélites LANDSAT 5, 7 e 8, respectivamente (SILVA *et al.*, 2018; MELAAS *et al.*, 2013) e o AVHRR a bordo do satélite NOAA (ZHANG *et al.*, 2018).

Muitos desses estudos, com foco na análise de grandes áreas, utilizam principalmente, séries temporais de índices de vegetação adquiridos por sensores de resolução moderada, como o MODIS, cuja resolução espacial é de 250 m, principalmente por ter alta resolução temporal (tempo de revisita de até um dia), como os trabalhos realizados na China (LI *et al.*, 2017; LU *et al.*, 2016) e na África (DI VITTORIO; GEORGAKAKOS, 2018).

Contudo, em áreas com heterogeneidade marcante, como ocorre na vegetação Caatinga, utilizar dados de sensores com resolução espacial moderada podem resultar em interpretações incorretas sobre a dinâmica da vegetação. Nesse sentido, imagens obtidas a partir de sensores de resolução espacial maiores, como o *Land Remote Sensing Satélite* (LANDSAT), cuja resolução espacial é de 30 m, são ideais por fornecerem informações espaciais muito mais detalhadas (LIU *et al.*, 2017; BOSCHETTI, 2015), por outro lado podemos perder a dinâmica temporal da Caatinga devida as rápidas mudanças no vigor vegetativo aos eventos de precipitação.

Além disso, ao utilizar séries temporais de dados do NDVI, muitas vezes é necessário contornar alguns problemas como, o espaçamento dos dados, que está relacionado com o tempo de revisita do satélite, bem como a ausência e/ou a contaminação dos dados, cuja causa está ligada a influência de nuvens e/ou da atmosfera, gerando ruído na série (JULIEN; SOBRINO, 2019).

### **3.4. Programa LANDSAT**

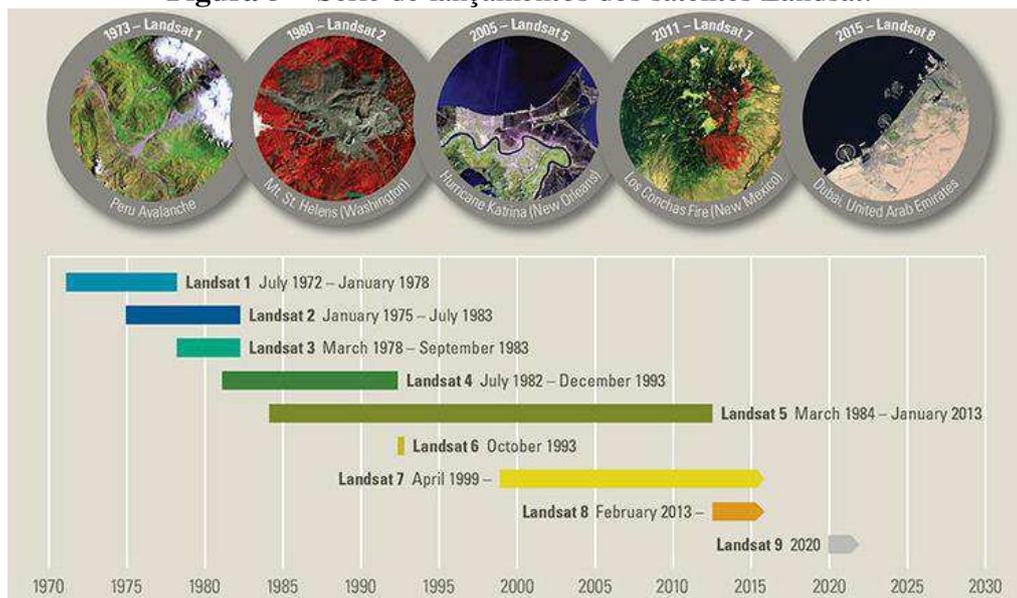
Desde 1972, os satélites da série Landsat criaram o mais longo arquivo de dados, adquiridos continuamente. Essa iniciativa conjunta da USGS (*United States Geological Survey*) com a NASA (*National Aeronautics and Space Administration*) apoia os estudos de sensoriamento remoto em todo o mundo e ajuda os administradores e formuladores de políticas a tomar decisões informadas sobre os recursos naturais e o meio ambiente (USGS, 2018).

O primeiro satélite civil de observação da Terra foi lançado em 23 de julho de 1972, chamado de satélite de tecnologia de recursos da Terra (ERTS), que mais tarde foi renomeado como Landsat 1. Os lançamentos do Landsat 2, Landsat 3 e Landsat 4 ocorreram em 1975, 1978 e 1982, respectivamente. (USGS, 2018).

Quando o Landsat 5 foi lançado em 1984, ninguém poderia prever que o satélite continuaria a fornecer dados globais de alta qualidade da superfície terrestre durante quase 29 anos, estabelecendo oficialmente um novo recorde mundial do Guinness para o satélite de observação da Terra com maior tempo de operação. O Landsat 6 não conseguiu atingir a órbita em 1993.

O Landsat 7 foi lançado com sucesso em 1999, o Landsat 8 em 2013, e ambos os satélites continuam a adquirir dados. O satélite Landsat 9 está sendo desenvolvido para uma data de lançamento em dezembro de 2020 (USGS, 2018). O histórico de lançamento da série de satélites Landsat está mostrado na Figura 5.

**Figura 5 – Série de lançamentos dos satélites Landsat.**



Fonte: USGS (2018).

### 3.4.1. LANDSAT 5

O Landsat 5 foi lançado da Base da Força Aérea de Vandenberg, na Califórnia, em 1º de março de 1984. O satélite superou e muito sua expectativa de vida útil do projeto original, que era de três anos, fornecendo dados de imagem da Terra por quase 29 anos, sendo desativado em 5 de junho de 2013 (USGS, 2018).

Sua instrumentação foi composta pelos sensores: Multispectral Scanner (MSS) e Thematic Mapper (TM). O primeiro sensor possuía quatro bandas espectrais, sendo elas: banda 4 - verde visível (0,5 a 0,6  $\mu\text{m}$ ), banda 5 - vermelho visível (0,6 a 0,7  $\mu\text{m}$ ), banda 6 - infravermelho próximo (0,7 a 0,8  $\mu\text{m}$ ) e banda 7 - infravermelho próximo (0,8 a 1,1  $\mu\text{m}$ ). Já o segundo sensor era capaz de capturar 7 bandas do espectro, incluindo uma banda térmica, sendo elas: banda 1 - visível (0,45 - 0,52  $\mu\text{m}$ ), banda 2 - visível (0,52 - 0,60  $\mu\text{m}$ ), banda 3 - visível (0,63 - 0,69  $\mu\text{m}$ ), banda 4 - infravermelho próximo (0,76 - 0,90  $\mu\text{m}$ ), banda 5 - infravermelho próximo (1,55 - 1,75  $\mu\text{m}$ ), banda 6 - térmica (10,40 - 12,50  $\mu\text{m}$ ) 120 m e a banda 7 - infravermelho médio (2,08 - 2,35  $\mu\text{m}$ ), todas com tamanho do pixel de 30x30 m (USGS, 2018).

O satélite Landsat 5 orbitou a Terra em uma órbita quase polar síncrono do sol, a uma altitude de 705 km, inclinado a 98,2 graus e circulou a Terra a cada 99 minutos, possuindo um ciclo de repetição de 16 dias. Os dados do Landsat 5 foram adquiridos no sistema de caminho / linha mundial Reference System-2 (WRS-2), com sobreposição de faixa variando

de 7% no Equador até um máximo de aproximadamente 85% em latitudes extremas. Mais de 2,7 milhões de cenas Landsat 5 estão disponíveis para baixar no EarthExplorer, GloVis e no Visualizador LandsatLook, que são portais da própria USGS. (USGS, 2018).

### **3.4.2. LANDSAT 7**

O Landsat 7 foi lançado da Base Aérea de Vandenberg, na Califórnia, em 15 de abril de 1999, no foguete Delta II. O satélite carrega o sensor Enhanced Thematic Mapper (ETM+). Desde junho de 2003, o sensor adquiriu e forneceu dados com falhas de dados causados pela falha do SLC (Scan Line Corrector). No final de 2020, o satélite Landsat 9 substituirá o Landsat 7 em órbita. O Landsat 7 possui o sensor Enhanced Thematic Mapper Plus (ETM+), uma versão melhorada dos instrumentos Thematic Mapper (TM) que estavam a bordo dos produtos Landsat 4 e Landsat 5. O Landsat 7 fornece imagens de 8 bits com 256 níveis de cinza. (USGS, 2018).

O sensor ETM+ realiza a leitura de oito bandas espectrais, incluindo uma banda panorâmica e uma térmica, sendo elas: banda 1 - visível (0,45 - 0,52  $\mu\text{m}$ ), banda 2 - visível (0,52 - 0,60  $\mu\text{m}$ ), banda 3 - visível (0,63 - 0,69  $\mu\text{m}$ ), banda 4 - infravermelho próximo (0,77 - 0,90  $\mu\text{m}$ ), banda 5 - infravermelho próximo (1,55 - 1,75  $\mu\text{m}$ ), banda 6 - térmica (10,40 - 12,50  $\mu\text{m}$ ), banda 7 infravermelho médio (2,08 - 2,35  $\mu\text{m}$ ) e a banda 8 - pancromática (PAN) (0,52 - 0,90  $\mu\text{m}$ ), sendo as bandas 1,2,3,4,5 e 7 com tamanho do pixel de 30 x 30 m, a banda 6 com pixel de tamanho 60 x 60 m e a banda 8 com tamanho de 15x15 m. (USGS, 2018).

O satélite Landsat 7 orbita a Terra em uma órbita quase polar síncrona ao sol, a uma altitude de 705 km, inclinada a 98,2 graus e circunda a Terra a cada 99 minutos. O satélite tem um ciclo de repetição de 16 dias com um tempo de cruzamento equatorial: 10:00 am +/- 15 minutos. Os dados Landsat 7 são adquiridos no sistema caminho/linha mundial Reference System-2 (WRS-2), com sobreposição de faixa variando de 7% no Equador até um máximo de aproximadamente 85% em latitudes extremas. Mais de 2,5 milhões de cenas criadas a partir de dados do sensor Enhanced Thematic Mapper Plus (ETM+) estão disponíveis para baixar gratuitamente através dos mesmos portais citados para o Landsat 5.

### **3.4.3. LANDSAT 8**

O Landsat 8 (primeiro conhecido como Missão de Continuidade de Dados Landsat) foi lançado em 11 de fevereiro de 2013 da Base da Força Aérea de Vandenberg, na

Califórnia, em um foguete Atlas-V. O satélite carrega os sensores Operational Land Imager (OLI) e o Thermal Infrared Sensor (TIRS) (USGS, 2018).

O sensor OLI realiza o processamento em 9 bandas espectrais, incluindo uma faixa panorâmica, sendo elas: Banda 1 - visível (0,43 - 0,45  $\mu\text{m}$ ), banda 2 - visível (0,450 - 0,51  $\mu\text{m}$ ), banda 3 - visível (0,53 - 0,59  $\mu\text{m}$ ), banda 4 visível (0,64 - 0,67  $\mu\text{m}$ ), banda 5 infravermelho próximo (0,85 - 0,88  $\mu\text{m}$ ), banda 6 - SWIR 1 (1,57 - 1,65  $\mu\text{m}$ ), banda 7 - SWIR 2 (2,11 - 2,29  $\mu\text{m}$ ), banda 8 - Pancromática (PAN) (0,50 - 0,68  $\mu\text{m}$ ) e a banda 9 Cirrus (1,36 - 1,38  $\mu\text{m}$ ), sendo a banda 8 com tamanho do pixel de 15 x 15 m e as demais com tamanho do pixel de 30 x 30 m. Já o sensor TIRS possui duas bandas espectrais, a banda 10 -TIRS 1 (10,6 - 11,19  $\mu\text{m}$ ) e a banda 11 - TIRS 2 (11,5 - 12,51  $\mu\text{m}$ ), ambas com tamanho do pixel de 100 x 100 m (USGS, 2018).

Cerca de 10.000 cenas foram adquiridas pelos sensores Operational Land Imager (OLI) e/ou Thermal Infravermelho Sensor (TIRS) após o lançamento (11 de fevereiro de 2013) até 10 de abril de 2013, quando o satélite atingiu a órbita operacional (WRS-2). As primeiras imagens são apenas dados TIRS. Estes dados também são visíveis e podem ser baixados do EarthExplorer ou GloVis. Atualmente, produtos de dados criados a partir de mais de 1,3 milhões cenas Landsat 8 OLI / TIRS também estão disponíveis para *download* nos portais supracitados.

### **3.5. Informações sobre a qualidade de dados em produtos de SRO**

Os produtos de qualidade de pixel (*Pixel Quality*) são fornecidos como dados prontos para análise e trazem aos usuários informações sobre as condições da superfície, da atmosfera e do sensor no momento da aquisição (Ernst et al., 2018).

Saber se uma observação foi afetada por nuvens é crucial ao selecionar dados para incluir em análises multitemporais desses produtos, pois observações imperfeitas ou incorretas são indesejáveis para a maioria das aplicações, como por exemplo, no estudo de mudanças de cobertura do solo (LU et al., 2016).

Para solucionar esse problema, provedores como o Serviço Geológico dos Estados Unidos (USGS) e a Agência Espacial Européia (ESA) fornecem dados prontos para análise (“*Analysis Ready Data*”) que incluem radiometria e calibração geométrica, assegurando consistência e comparabilidade de dados e sinalizadores de qualidade de pixel. Para USGS essa informação é fornecida através de uma banda de qualidade chamada de “*pixel\_qa.*”

As informações de qualidade fornecem aos usuários uma gama de metadados. Isso inclui informações sobre se uma observação foi afetada pela nuvem, sombra da nuvem ou saturação no momento da aquisição no nível por pixel. Esta informação é inestimável para selecionar dados para incluir em análises automatizadas (Ernst *et al.*, 2018).

Muitos trabalhos têm utilizado essas informações de qualidade para remoção de dados contaminados por nuvens e sombra de nuvens (Potapov *et al.*, 2012; LU *et al.*, 2016; Ernst *et al.*, 2018, entre outros) e obtiveram êxito ao analisarem as séries de dados limpas de nuvens.

### **3.6. Séries temporais de dados de SRO**

Séries temporais de dados de sensoriamento remoto são uma fonte importante de informações para entender a dinâmica da vegetação, que pode ser definida ao longo de várias escalas de tempo. No curto prazo, as plantas apresentam fenologias sazonais que normalmente seguem ciclos anuais. Entre os anos, os marcadores fenológicos (por exemplo, início do verdor, duração da estação de crescimento) podem responder de forma diferente. Essas mudanças são afetadas por flutuações climáticas de curto prazo (por exemplo, temperatura, precipitação) e/ou ações antropogênicas (por exemplo, agricultura, desmatamento, queimadas, etc.). A longo prazo, as fenologias anuais das plantas podem mudar como resultado de alterações climáticas e perturbações antrópicas em grande escala. (BRADLEY *et al.*, 2007).

A diferenciação de padrões fenológicos anuais, interanuais e de longo prazo é um componente importante da monitoração e modelagem de ecossistemas globais e pode levar a um melhor entendimento de como e por que mudanças na cobertura do solo ocorrem ao longo do tempo (Potter *et al.*, 2003).

Tendências anuais, interanuais e de longo prazo em séries temporais derivadas de sensoriamento remoto podem ser usadas para distinguir entre a variabilidade natural da cobertura do solo (ação climática) e a mudança da cobertura do solo causada pelo homem (ação antrópica), como foi feito por CUNHA (2018), LU *et al.* (2016), entre outros.

No entanto, a utilidade de usar a fenologia derivada do NDVI, por exemplo, para detectar mudanças, é muitas vezes limitada por dados de baixa qualidade resultantes de efeitos atmosféricos e outros efeitos, além da baixa quantidade de dados ocasionada pela presença constante de cobertura de nuvens em algumas regiões. (BRADLEY *et al.*, 2007).

Para curto prazo, entender as respostas da planta aos eventos de chuva, principalmente em vegetações muito sensíveis a presença de água, como é o caso da Caatinga, é necessário um acompanhamento diário da planta, o que muitas vezes se torna difícil a partir de dados de satélites, os quais são afetados pela presença de nuvens. O que se propõe para esses estudos é reconstruir as séries temporais de índices de vegetação, obtendo valores em escala diária desses índices.

### **3.7. Preenchimento de falhas em séries temporais de NDVI**

Quando se observa a vegetação do espaço, a presença mais do que ocasional de nuvens diminui a utilidade dos dados, já que o processo de mascaramento de nuvens gera lacunas de dados nas séries temporais. Em clima temperado e em outras áreas, a estimativa das fases da fenologia da vegetação a partir das séries temporais de NDVI, como o início e o final da estação, é complicada pela cobertura de nuvens, muitas vezes persistentes, nas estações de primavera e outono. Isso tem fortes implicações para a caracterização da atividade vegetal, e também para a recuperação dos principais parâmetros fenológicos, considerados como indicadores de resposta da vegetação às mudanças climáticas. Sendo assim, a análise de preenchimento de falhas é essencial para assegurar uma aplicação apropriada dos produtos NDVI (JULIEN; SOBRINO, 2019; CAO *et al.*, 2018; JULIEN; SOBRINO, 2018; MONDAL *et al.*, 2017).

Embora os conjuntos de dados NDVI sejam pré-processados com o objetivo de minimizar os ruídos oriundos da calibração do sensor, de erros de quantização digital, de condições de solo e atmosféricas, parte dessas interferências ainda estão presentes nos conjuntos de dados disponibilizados pela USGS para download (MOTOHKA *et al.*, 2011). Diante dessa realidade, dados de séries temporais de NDVI precisam ser analisados antes da aplicação de qualquer filtro (MIGLANI *et al.*, 2011).

Na literatura, é possível encontrar a aplicação de filtro a dados sem nuvens, ou seja, aqueles em que já foi aplicada uma máscara inicial para remoção dos valores de pixels associados à presença de nuvens, bem como a dados com contaminação de nuvens, nos quais não foi feita aplicação de nenhuma máscara. A simulação de dados sem nuvens é geralmente realizada através da média dos dados reais ao longo de vários anos (HIRD; MCDERMID, 2009; MICHISHITA *et al.*, 2014; MORENO *et al.*, 2014; ZHOU *et al.*, 2015), uma vez que fornece uma forma realista do sinal anual da vegetação. No entanto, a simulação pode ser realizada utilizando todas as aquisições disponíveis ou apenas as aquisições marcadas como

sem nuvem. Embora o último caso forneça uma série temporal de referência melhor para o teste de aplicação do filtro, o efeito de nuvens não detectadas pode ser significativo, especialmente em áreas com cobertura regular de nuvens. Nesse caso, a escolha da máscara de remoção de nuvens deve ser cuidadosa.

Por outro lado, Geng *et al.* (2014) utilizaram uma abordagem conjunta para construir uma série temporal de referência baseada na média das séries temporais reconstruídas com diferentes métodos. No entanto, essa abordagem distorce a estimativa do erro na reconstrução, uma vez que alguns métodos usam uma abordagem de envelope superior para detectar dados contaminados com nuvens e, portanto, sempre fornecerá uma série temporal reconstruída acima da série de referência.

Sendo assim, muitos trabalhos foram desenvolvidos na tentativa de preencher a lacuna de dados (VANDIJK *et al.*, 1987; CHEN *et al.*, 2004; BECK *et al.*, 2006; HIRD; MCDERMID, 2009; JULIEN; SOBRINO, 2010; CHO; SUH, 2013; KE *et al.*, 2013; LIN *et al.*, 2014; MORENO *et al.*, 2014; XIAO *et al.*, 2015; XU *et al.*, 2015; YANG *et al.*, 2015; ZHOU *et al.* 2015). Essas abordagens, denominadas métodos de reconstrução de séries temporais ou de preenchimento de falhas visam fornecer dados alternativos para observações contaminadas por nuvens. No caso da vegetação, considerando que sofre pequenas alterações ao longo de alguns dias (HOLBEN, 1986), os métodos de reconstrução de séries temporais podem oferecer uma estimativa do valor real, recuperando o parâmetro NDVI abaixo da cobertura de nuvens. Além disso, alguns métodos podem, além de preencher as lacunas, fornecer dados de NDVI em escalas temporais mais detalhadas do que as que foram utilizadas para aplicação do filtro.

Existem dois tipos principais de métodos de reconstrução de séries temporais de IVs. O primeiro é fundamentado em técnicas de filtragem, no qual um filtro pré-definido é empregado para preencher as lacunas e suavizar a série temporal utilizando uma janela móvel local, como o filtro Savitzky-Golay (SG) (CHEN *et al.*, 2004), o filtro de iteração de valor médio (JULIEN; SOBRINO, 2010), o filtro Whittaker (ATZBERGER; EILERS, 2011) e o filtro de mudança de peso (ZHU *et al.*, 2012). O segundo tipo é baseado em curvas de ajuste, no qual uma função matemática, geralmente não-linear, é utilizada para simular o crescimento sazonal da vegetação. Essas funções incluem a função assimétrica de Gauss (AG) (JÖNSSON; EKLUNDH, 2002), a função logística dupla (DL) (BECK *et al.*, 2006), o método de Fourier (ROERINK *et al.*, 2000), o spline cúbico (CHEN *et al.*, 2006), etc.

Funções de distribuições estatísticas também são utilizadas com o mesmo objetivo. Julien e Sobrino (2018) aplicaram cinco distribuições estatísticas (Gaussiana ou Normal,

Cauchy, Log-normal, distribuição Gamma e Gaussiana discreta) em séries de imagens globais de NDVI AVHRR-NOAA sem nuvens e contaminadas com nuvens, para diferentes tipos de cobertura de terra. Os autores utilizaram o teste estatístico de Kolmogorov-Smirnov para verificar a eficiência dos ajustes e concluíram que as distribuições Gaussiana e Cauchy modelaram melhor as séries de NDVI contaminadas com nuvens, enquanto que as distribuições Gaussiana e Gaussiana discreta foram melhores para ajustar os dados sem nuvens.

Além disso, as funções Gaussiana e Cauchy apresentaram bom desempenho tanto em dados contaminados com nuvens como em dados sem nuvens, já as funções Log-Normal e Gamma foram ruins em ambos os casos. A influência da cobertura da terra na seleção do melhor modelo também foi analisada, embora o modelo de melhor desempenho foi o mesmo (Gaussiano) para todas as classes de cobertura, com apenas pequenas variações da estatística de Kolmogorov-Smirnov. Por fim, os autores analisaram se a seleção do melhor modelo dependia do tempo. Para tanto, selecionaram para cada pixel aleatório de cada Dia Juliano (DJ) o melhor modelo para distribuição de valores NDVI, e determinaram a porcentagem de pixels para os quais cada método correspondeu ao melhor modelo. Com isso, concluíram que a distribuição Gamma tem um desempenho ruim para todos os DJ's, enquanto o modelo Gaussiano é o melhor para todos os DJ's e é bastante estável ao longo do ano, sendo o modelo de Cauchy bastante semelhante ao Gaussiano, em termos de porcentagem de pixels em que apareceu como melhor ajuste.

Quanto as verificações de eficiência dessas séries ajustadas, por exemplo, para dados contaminados com nuvens, podem ser encontradas três abordagens diferentes: introdução de ruído, introdução aleatória de lacunas e introdução de intervalos de tempo-realista. A introdução de ruído é fundamentada na adição de ruídos aleatórios de diferentes amplitudes na série temporal de referência. Como a contaminação por nuvens tende a diminuir os valores de NDVI, essa abordagem, embora válida para indicar a sensibilidade do método ao ruído, é inadequada para estimar os erros do método, uma vez que aproximadamente metade dos valores gerados contaminados pela nuvem estão acima dos valores da série temporal de referência (MICHISHITA *et al.*, 2014; MORENO *et al.*, 2014).

Com relação a introdução aleatória usada por Hird e McDermid (2009), foram incluídos valores realistas de NDVI contaminados por nuvens, enquanto a distribuição temporal de valores contaminados por nuvens permaneceu longe de ser realista. Finalmente, uma introdução de lacunas mais eficiente foi fornecida recentemente por Zhou *et al.* (2015), através da determinação em escala global de uma proporção de lacunas nos dados, levando

em consideração o tempo e a possibilidade de cobertura de nuvens persistentes. Sendo assim, essa abordagem preencheu os pixels simulados contaminados com um valor inválido, que torna mais fácil para o método de reconstrução identificar nuvens e ficou restrito a séries temporais bimestrais.

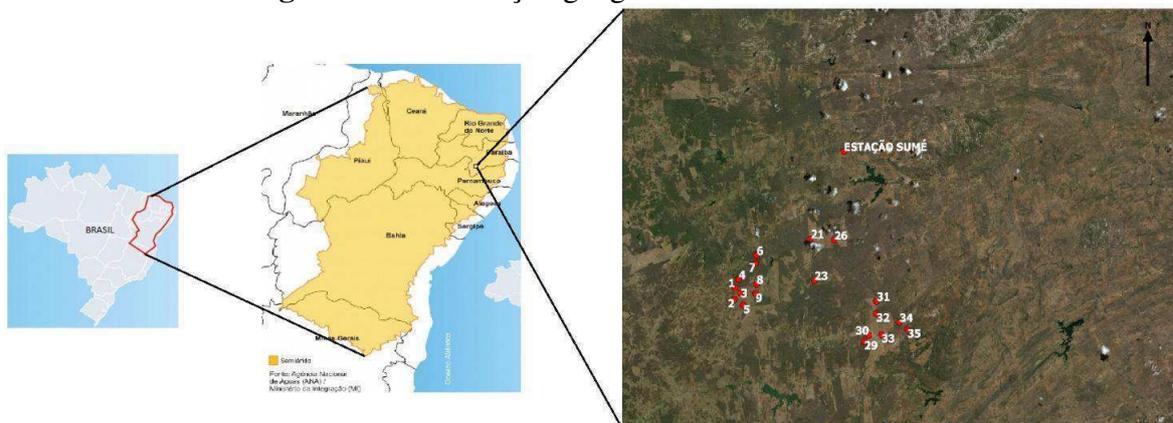
É notório que, para métodos baseados na aplicação prévia de sinalizadores de nuvem em séries temporais, o valor real do NDVI contaminado por nuvem é irrelevante, uma vez que apenas os dados sem nuvens são considerados para a reconstrução. No entanto, a rotulagem errada da aquisição sempre pode ocorrer, e erros de omissão e comissão podem influenciar a reconstrução da série temporal (JUIEN; SOBRINO, 2018).

## 4. METODOLOGIA

### 4.1. Área de estudo

Situada entre os municípios de Monteiro, Camalaú, Sumé e Prata, no estado da Paraíba, está a área de estudo desta pesquisa, cuja localização geográfica é indicada na Figura 6, sendo avaliada neste trabalho através de um recorte delimitado pelos pontos extremos de coordenadas  $(-37.121^\circ, -7.641^\circ)$  e  $(-36.719^\circ, -7.944^\circ)$  da cena Landsat 215/065 (órbita/ponto), selecionando 19 pontos representativos, dos quais 4 são de vegetação Caatinga preservada e 15 de vegetação que sofreu alguma mudança na cobertura do solo ocasionada por ação antrópica, segundo estudo de Cunha (2018).

**Figura 6** – Localização geográfica da área de estudo.



Fonte: Próprio autor.

De acordo com a classificação de Köppen, o clima da região é do tipo climático BSh, ou seja, seco (semiárido), caracterizado por insuficiência e irregularidade das precipitações

pluviais e ocorrência de temperaturas elevadas (CADIER *et al.*, 1983). A precipitação pluvial média anual, no período de 1994 a 2017, foi de 515 mm e a temperatura média anual é de 24°C.

A sua área de compreensão está totalmente inserida no Semiárido do Brasil, nos domínios da Caatinga com inúmeras variações paisagísticas. O IBGE (2018) a classifica como Savana Estépica, com área mais representativa abrangendo a Caatinga do Semiárido Nordeste, a qual possui endemismo marcante com relativa riqueza biológica e diversas formações vegetais, como as gramíneas, arbustos e árvores de porte variado, caducifólias, enorme variedade de plantas espinhosas, cactáceas e bromeliáceas.

Na área de estudo, a vegetação é composta prioritariamente por arbustos que perdem as folhas nos meses mais secos ou por pastagens que secam na época de estiagem, e possui como principais atividades econômicas a agricultura e a pecuária (ALVES, 2012; CUNHA, 2018). A condição de semiaridez dominante na região de estudo propicia o surgimento de processos naturais de retrogressão bióticas nos períodos de secas mais prolongadas, que associados à pressão antrópica, têm levado à degradação edáfica e biótica de caráter as vezes irreversível, processos que podem ocasionar a desertificação na região (MOURA *et al.*, 2005).

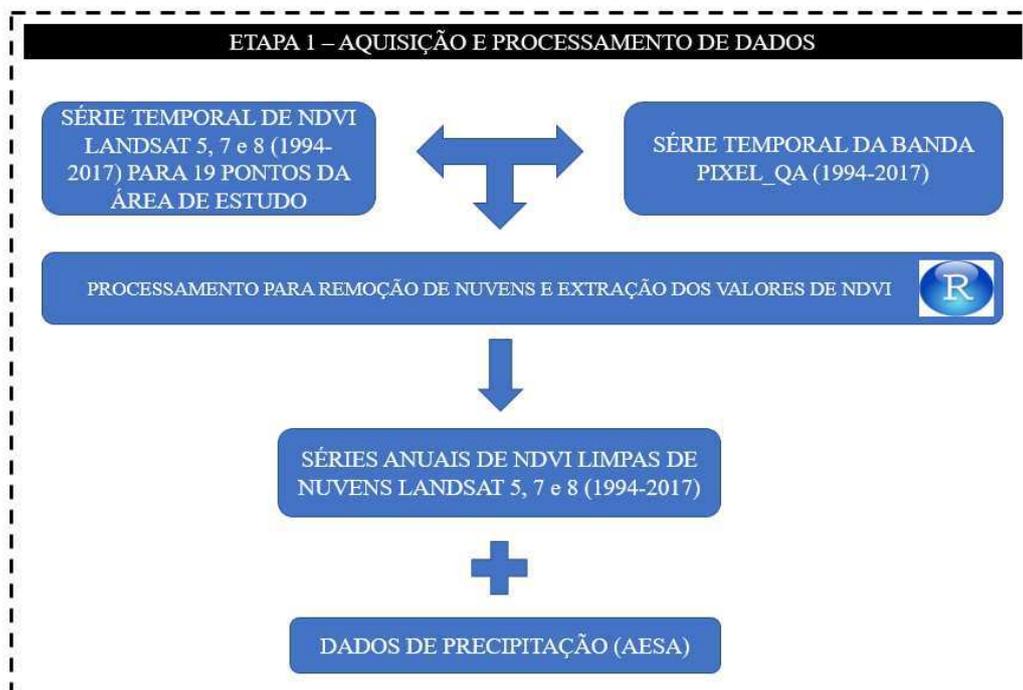
#### **4.2. Etapas metodológicas**

Este trabalho está fundamentado em uma metodologia composta por quatro etapas subsequentes: aquisição e processamento de dados, definição da função de ajuste, aplicação da função de ajuste e validação da função de ajuste.

Na primeira etapa estão descritos como os dados foram adquiridos e pré-processados para aplicação desse estudo. A segunda etapa descreve como foi obtida a melhor função de ajuste para os dados obtidos na primeira etapa. Na terceira etapa essa função é utilizada para reconstruir séries de NDVI em diversos pontos de vegetação Caatinga. Na quarta etapa verificou-se a eficiência desses ajustes a partir de comparações com outras funções amplamente utilizadas na literatura. Cada uma dessas etapas estão descritas a seguir.

#### 4.2.1. Aquisição e processamento dos dados

Figura 7 – Fluxograma da primeira etapa metodológica



Fonte: Próprio autor.

Neste estudo foram utilizadas imagens de NDVI de órbita 215 e ponto 65, obtidas de forma direta através da plataforma on-line do Serviço Geológico Americano – United States Geological Survey– USGS (<https://espa.cr.usgs.gov/>), na seção Order Data, do período de 1994 a 2017, dos sensores Thematic Mapper -TM , satélite Landsat 5, Enhanced Thematic Mapper plus – ETM+, satélite Landsat 7, e Operational Land Imager – OLI, satélite Landsat 8. Este índice é calculado como uma combinação linear das bandas do vermelho (RED) e do infravermelho próximo (NIR), conforme a Equação 1 e está intimamente relacionado com a atividade fotossintética da vegetação (JENSEN, 2009).

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

A escolha da série Landsat ocorreu em virtude da disponibilidade gratuita dos dados, por representar uma série longa (mais de 30 anos) e por sua resolução espacial (30 m) que é compatível com a heterogeneidade da Caatinga.

Já a escolha do período (1994-2017) se deve ao fato de representar uma série temporal que contém variações extremas de precipitação, ou seja, possui tanto anos muito chuvosos como, por exemplo, 2009 (890,2 mm), como também anos muito secos, como 2012 (27,0 mm), o que é importante para a análise do índice em diversos cenários de chuva. Os dados diários de precipitação foram obtidos junto à Agência Executiva de Gestão das

Águas do Estado da Paraíba (AESAs), como indicado na Figura 7, cujo posto pluviométrico de origem está localizado no município de Sumé-PB, ponto mais próximo da área de estudo com dados disponíveis.

O processamento das imagens foi feito no software R, para remoção das nuvens e extração dos valores de NDVI nos pontos de interesse, cujas coordenadas estão dispostas na Tabela 2. A retirada de nuvens foi feita baseada na banda “pixel\_qa”, adquirida junto aos produtos de NDVI na plataforma da USGS. Através de ferramentas disponibilizadas no *RStudio*, foram selecionados os pixels que estavam associados a níveis de alta confiabilidade de ausência de nuvens (“clear” - Tabela 3), inserindo NA (Not Available) em todos os demais pixels do NDVI. Dessa forma, os pixels marcados como nuvem ou sombra de nuvens foram excluídos das séries anuais de dados.

**Tabela 2** – Coordenadas dos pontos da área de estudo e seus status com relação à ação antrópica.

PONTO	COORDENADA X	COORDENADA Y	STATUS DA VEGETAÇÃO
1	-37,0603	-7,7954	ALTERADA
2	-37,0610	-7,8080	ALTERADA
3	-37,0537	-7,8013	ALTERADA
4	-37,0559	-7,7865	ALTERADA
5	-37,0508	-7,8141	ALTERADA
6	-37,0351	-7,7609	SEM ALTERAÇÃO
7	-37,0364	-7,7695	ALTERADA
8	-37,0353	-7,7918	SEM ALTERAÇÃO
9	-37,0363	-7,8020	ALTERADA
21	-36,9720	-7,7431	ALTERADA
23	-36,9676	-7,7877	SEM ALTERAÇÃO
26	-36,9445	-7,7445	SEM ALTERAÇÃO
28	-36,9159	-7,7945	ALTERADA
30	-36,9040	-7,8463	ALTERADA
31	-36,8950	-7,8100	ALTERADA
32	-36,8954	-7,8232	ALTERADA
33	-36,8892	-7,8455	ALTERADA
34	-36,8682	-7,8326	ALTERADA
35	-36,8591	-7,8401	ALTERADA

Fonte: CUNHA (2018).

A banda pixel\_qa foi então utilizada como filtro nesse processo, cujos rótulos estão indicados na Tabela 3. O processamento realizado pela USGS, para gerar a banda “pixel\_qa” é feito com base no algoritmo em linguagem C, chamado de CFMask, que tem função de máscara. O algoritmo é usado para mapear a nuvem, a confiabilidade na nuvem, a sombra

da nuvem e os pixels de neve e gelo. O CFMask é um algoritmo de múltiplas passagens que primeiro marca os pixels com base em uma árvore de decisão classificadora e, em seguida, a validação ou o descarte dos rótulos atribuídos inicialmente aos pixels é feita com base em estatísticas de toda a cena. A máscara de sombra é criada projetando iterativamente no solo nuvens de diferentes alturas (MARKERT *et al.*, 2018; FOGA *et al.*, 2017). Pixels marcados como nuvem ou sombra de nuvens foram mascarados na coleta de dados do Landsat.

**Tabela 3** – Valores da banda pixel\_qa utilizados como filtro para remoção de nuvens.

SATÉLITE	VALORES DOS PIXELS	ATRIBUIÇÃO
LANDSAT 5 E 7	66; 130	LIMPO DE NUVENS
LANDSAT 8	322; 386; 834	LIMPO DE NUVENS

Fonte: USGS (2018).

#### 4.2.2. Definição da função de ajuste

**Figura 8** – Fluxograma da segunda etapa metodológica.



Fonte: Próprio autor.

Para identificação da curva que obtivesse um melhor ajuste dos dados de NDVI foram necessários alguns procedimentos que estão resumidos na Figura 8. Foi utilizado o software LAB FIT desenvolvido por SILVA *et al.* (2004), no qual funções não-lineares são ajustadas aos dados originais inseridos e, a partir de uma biblioteca dessas funções, o

programa define um ranking das 10 melhores, com base no parâmetro estatístico do qui-quadrado reduzido ( $\chi^2$ ). A utilização desse software para a escolha da função deveu-se ao fato de possuir um leque de mais de 200 funções não-lineares.

Para realização dos testes, os dados de NDVI foram separados anualmente para quatro pontos da área de estudo, sendo eles: 6, 8, 23 e 26, nos quais não houve antropização. A seleção desses pontos onde não ocorreram mudanças é importante para essa análise inicial, para a obtenção de uma única função que represente o comportamento sazonal da vegetação, tornando-se mais confiável e válida para o tipo de cobertura do solo em estudo. Sendo assim, os dados foram processados no LAB FIT com o objetivo de verificar a melhor função de ajuste para cada ano.

Portanto, a curva presente no ranking das dez melhores com maior frequência, ou seja, para um maior número de anos, foi escolhida para o ajuste dos dados, sendo utilizada nos demais pontos. Os anos com dados mal distribuídos (que não contenham pelo menos, 2 dados num intervalo de 4 meses) e/ou com poucos dados (menos do que seis valores de NDVI na série), foram excluídos da análise, afastando a possibilidade de o não-ajuste ser ocasionado por essas falhas nas séries, pois segundo Kandasamy *et al.* (2013), a lacuna de dados afeta o preenchimento de falha na maioria dos filtros. A escolha destes critérios para exclusão das séries anuais de NDVI foi baseada em testes preliminares. A partir destes testes foi constatado que as séries que apresentavam grandes lacunas e baixa quantidade de dados impossibilitavam que o ajuste ocorresse, e por isso, elas foram excluídas da análise.

#### **4.2.3. Aplicação da função de ajuste**

Uma vez definida a função de ajuste (etapa 2), a metodologia segue com a aplicação da mesma (etapa 3), resumida na Figura 9. A função escolhida foi aplicada para os 15 pontos na área de estudo onde houve alteração da cobertura do solo, num total de 360 séries de dados de NDVI, para uma análise do comportamento da curva em situações onde a vegetação foi alterada e/ou removida, no intuito de verificar se mesmo após uma mudança de cobertura a função se ajustaria bem aos dados, o que implicaria que, independente da cobertura, o ajuste seria capaz de reconstruir a série de NDVI. Para essa análise foi considerado que as séries que obtivessem  $R^2$  abaixo de 0,70, não seriam aplicáveis em futuros estudos sobre a fenologia e a interação vegetação-clima, pois a confiança no valor do NDVI abaixo de 70 % poderia ocasionar, por exemplo, erros na interpretação dos parâmetros de início e fim da

temporada de crescimento da vegetação, e como esse trabalho tem o intuito de gerar uma ferramenta que possibilite essas análises, esse foi o limiar utilizado para o  $R^2$ .

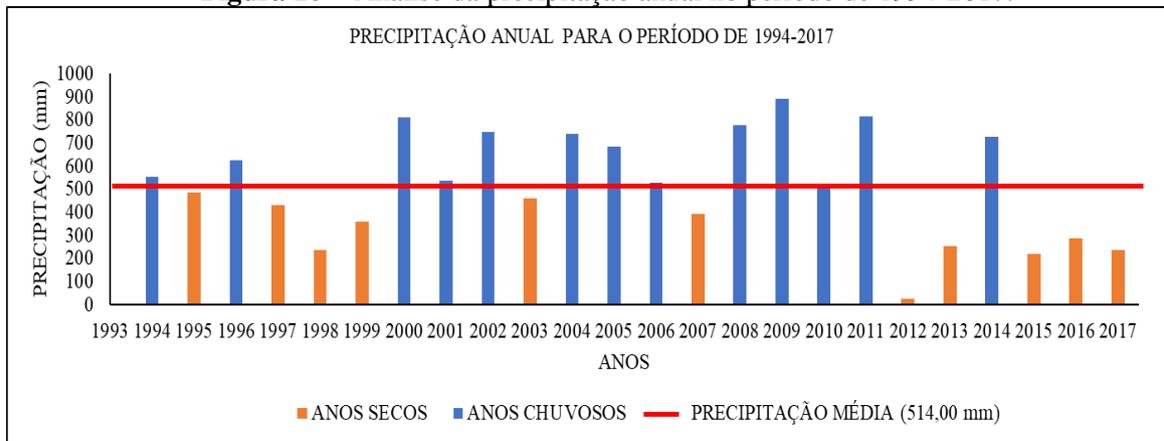
**Figura 9** – Fluxograma da terceira etapa metodológica



Fonte: Próprio autor.

Além disso, foi analisado o comportamento do índice com relação aos ciclos anuais de precipitação, levando em consideração os anos secos e chuvosos. Para essa verificação, foi estabelecido que os anos secos seriam aqueles em que a precipitação fosse inferior a média para o período (1994-2017) e os anos chuvosos aqueles em que a precipitação fosse igual ou superior à média, como está ilustrado na Figura 10.

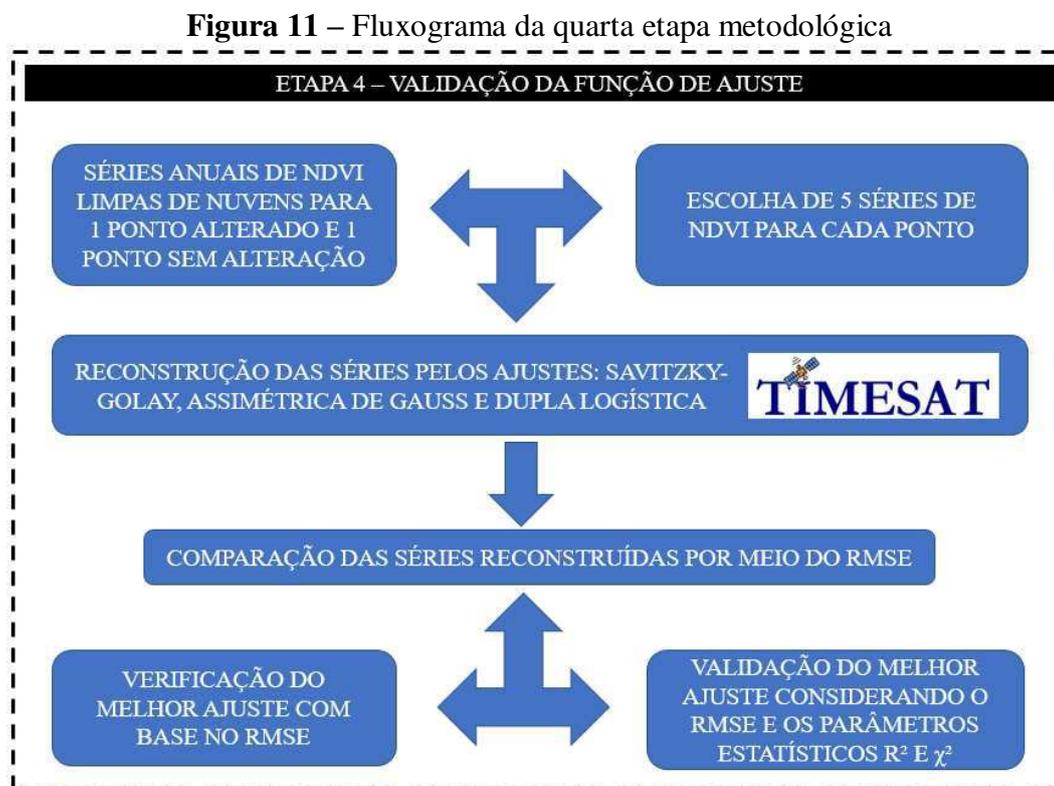
**Figura 10** – Análise da precipitação anual no período de 1994-2017.



Fonte de dados: AESA (2018).

#### 4.2.4. Validação do ajuste

A última etapa metodológica deste trabalho está resumida na Figura 11.



Fonte: Próprio autor.

Na literatura, é possível encontrar duas formas principais de validação de uma série ajustada de dados de NDVI (JULIEN; SOBRINO, 2018; ZHOU *et al.*, 2015; MICHISHITA *et al.*, 2014; MORENO *et al.*, 2014; HIRD; MCDERMID, 2009). A primeira é adicionando ruídos na série original (com nuvens) de dados e comparando essa nova série com a série original, a fim de verificar o erro entre esses valores. Esses ruídos são controlados e construídos a fim de se obter respostas para cada tipo de ruído e seu respectivo erro, sendo possível identificar se a função está apresentando bom desempenho no ajuste dos dados de acordo com esses erros.

Outra forma é calcular o erro entre a série ajustada e a série de referência (valores limpos de nuvens), e depois comparar o desempenho dessa função com o de outros ajustes que são amplamente utilizados em todo o mundo, verificando o erro de cada uma com relação a série de referência.

Neste estudo, para a validação do ajuste, foi utilizada esta última forma. A comparação foi feita com as funções matemáticas Assymmetric Gaussian (AG) e Double

Logistic (DL) e com o filtro Savitsky-Golay (SG), utilizando o software TIMESAT (JÖNSSON; EKLUNDH, 2004) para o processamento dessas funções. O critério comparativo foi a Erro Quadrático Médio da Raiz (RMSE) de cada função com relação aos valores originais.

Para comparação da série de referência (dados sem nuvem) com as séries temporais reconstruídas utilizando a função Cauchy e os filtros Savitzky-Golay -SG (CHEN *et al.*, 2004), a função Assimétrica de Gauss -AG (JÖNSSON; EKLUNDH, 2002) e a função Dupla Logística - DL (BECK *et al.*, 2006), foi necessária a utilização do software TIMESAT (JÖNSSON, P.; EKLUNDH, L., 2004), para reconstrução das séries. O software LAB FIT, não possui em sua biblioteca os ajustes SG e DL, e por isso foi utilizado para reconstruir apenas as novas séries ajustadas pela função Cauchy.

Para utilização do TIMESAT foi necessária a adequação das séries utilizadas, uma vez que o software requer valores de NDVI com intervalo temporal igual. Com isso, definimos o intervalo mensal. Nos meses onde não obtivemos nenhum valor de NDVI, foi inserido um valor fora da grandeza dos valores para que o software entendesse como uma lacuna. Já nos meses que tínhamos mais de um valor de NDVI, apenas um foi utilizado, sendo os outros eliminados.

Um ponto de Caatinga preservada (6) e um ponto onde houve alteração de cobertura (33) foram avaliados, com uma série de 5 anos para cada ponto, totalizando 10 séries analisadas, onde os ajustes foram aplicados e por fim o RMSE foi calculada para cada função verificada com relação a série original de NDVI (série de referência) para cada ano. O RMSE indica o quão próximo os valores ajustados estão dos valores observados, quanto menor for o valor do RMSE mais próximos os valores ajustados estão daqueles observados. O RMSE é um índice comumente usado para avaliar a precisão (CHEN *et al.*, 2011). Esse critério de comparação entre os ajustes também foi utilizado por Kandasamy *et al.* (2013) quando compararam oito métodos de ajustes de curvas para séries de IVs, os quais consideraram bem referenciados e baseados em técnicas de ajuste de curvas locais ou em técnicas de decomposição, nos quais as funções AG e DL, bem como o filtro SG estavam incluídos.

## **5. RESULTADOS E DISCUSSÃO**

### **5.1. Obtenção das séries de NDVI limpas de nuvens**

Uma vez obtidas as imagens de NDVI gratuitamente a partir do portal online da USGS, foi aplicada a banda “pixel\_qa” como filtro para remoção de nuvens, utilizando os valores indicados na Tabela 3, com script construído em linguagem de programação R.

Inicialmente, obtivemos 11.457 valores de NDVI considerando todos os pontos em estudo dentro do período analisado (1994-2017). Após a aplicação da máscara “pixel\_qa” foram removidos 5.779 valores de NDVI duvidosos, o que corresponde à 50,45% dos valores obtidos, restando apenas 5.678 dados de NDVI (49,55%).

Isso quer dizer que, em média, 50% das vezes que o satélite passou por qualquer um dos pontos, ele não conseguiu captar os valores de reflectância da superfície terrestre impedido pela cobertura de nuvens. Isso mostra o quanto a área de estudo é afetada pelas nuvens, gerando lacuna nos dados, o que indica a importância cada vez maior da utilização de procedimentos para análise de padrões a partir de dados de sensoriamento remoto, como a aplicação de ajuste de curvas para reconstrução da série.

## 5.2. Curva de ajuste

Após o processamento dos dados de NDVI dos pontos de Caatinga preservada (6, 8, 23 e 26), foram obtidos 24 anos de dados para cada sítio (1994-2017), num total de 96 séries de dados. Dessas séries, 22 apresentaram dados mal distribuídos e em 15 os dados apresentaram-se, tanto em baixa quantidade como mal distribuídos, somando 37 séries excluídas da análise. Sendo assim, 59 séries de NDVI foram utilizadas no LAB Fit, para definição da melhor função de ajuste. A função de Cauchy foi a que apresentou melhor ajuste, o que pode ser verificado na Tabela 4. A mesma ajusta-se com maior frequência (66%) em todos os pontos analisados.

**Tabela 4** – Frequência da função Cauchy para os pontos de Caatinga preservada.

PONTO	Nº DE SÉRIES	AJUSTE	FREQ.	(%)	$\chi^2$ REDUZIDO MÉDIO
6	15	$Y = 1/(A x (B + X)^2) + C$	11	73%	0,005770955
8	15	$Y = 1/(A x (B + X)^2) + C$	11	73%	0,005770955
23	17	$Y = 1/(A x (B + X)^2) + C$	10	59%	0,004283285
26	12	$Y = 1/(A x (B + X)^2) + C$	7	58%	0,004443691
TOTAL	59	$Y = 1/(A x (B + X)^2) + C$	39	66%	0,005067221

Fonte: Próprio autor.

Outras funções apresentaram frequências inferiores à função Cauchy, como por exemplo, a função Assimétrica de Gauss (54%), Potência 2 (53%), Equação polinomial do 3º grau (42%), entre outras (Tabela 5). Contudo, a função Exponencial 2 apresentou a mesma frequência da Cauchy (66%) e, portanto, para critério comparativo foi verificado o Qui-Quadrado reduzido médio ( $\chi^2$  reduzido médio) de ambas as funções.

**Tabela 5** – Desempenho dos melhores ajustes encontrados.

AJUSTE	EQUAÇÃO	FRQ.	(%)	$\chi^2$ REDUZIDO MÉDIO
Cauchy	$Y = 1 / (A \cdot (B + X)^2) + C$	39	66%	5,07E-03
Exponencial 2	$Y = A \cdot e^{(B \cdot X + C \cdot \sqrt{X})}$	39	66%	6,67E-03
Gaussiana	$Y = A \cdot e^{\frac{(X-B)^2}{c}}$	32	54%	6,69E-03
Potência 2	$Y = A \cdot X^{(B+C \cdot X)}$	31	53%	6,21E-03
Hoerl	$Y = A \cdot (B^X) \cdot X^C$	30	51%	5,72E-03
Equação Polinomial do 3º grau	$Y = A \cdot X + B \cdot X^2 + C \cdot X^3$	25	42%	6,91E-03
-	$Y = A \cdot \text{SENH}(B \cdot X) + C \cdot X^2$	23	39%	6,78E-03
Cosseno	$Y = A \cdot \text{COS}(B \cdot X + C)$	21	36%	8,96E-03
Exponencial x linha Reta	$Y = A \cdot X \cdot e^{(B \cdot X)}$	20	34%	8,57E-03
Exponencial 3	$Y = A \cdot e^{\left(\frac{B}{X} + C \cdot X\right)}$	19	32%	4,69E-03

Fonte: Próprio autor.

A função Cauchy (Eq. 2) então foi definida como melhor ajuste para a área de estudo por apresentar o menor valor do  $\chi^2$  reduzido médio ( $5,07 \times 10^{-3}$ ), enquanto a função exponencial 2 apresentou um valor de  $6,67 \times 10^{-3}$ .

$$Y = \frac{1}{A \cdot (B + X)^2 + C}$$

(2)

Onde, Y é o valor correspondente de NDVI para cada dia juliano (X) do ano analisado, sendo A, B e C os parâmetros da equação.

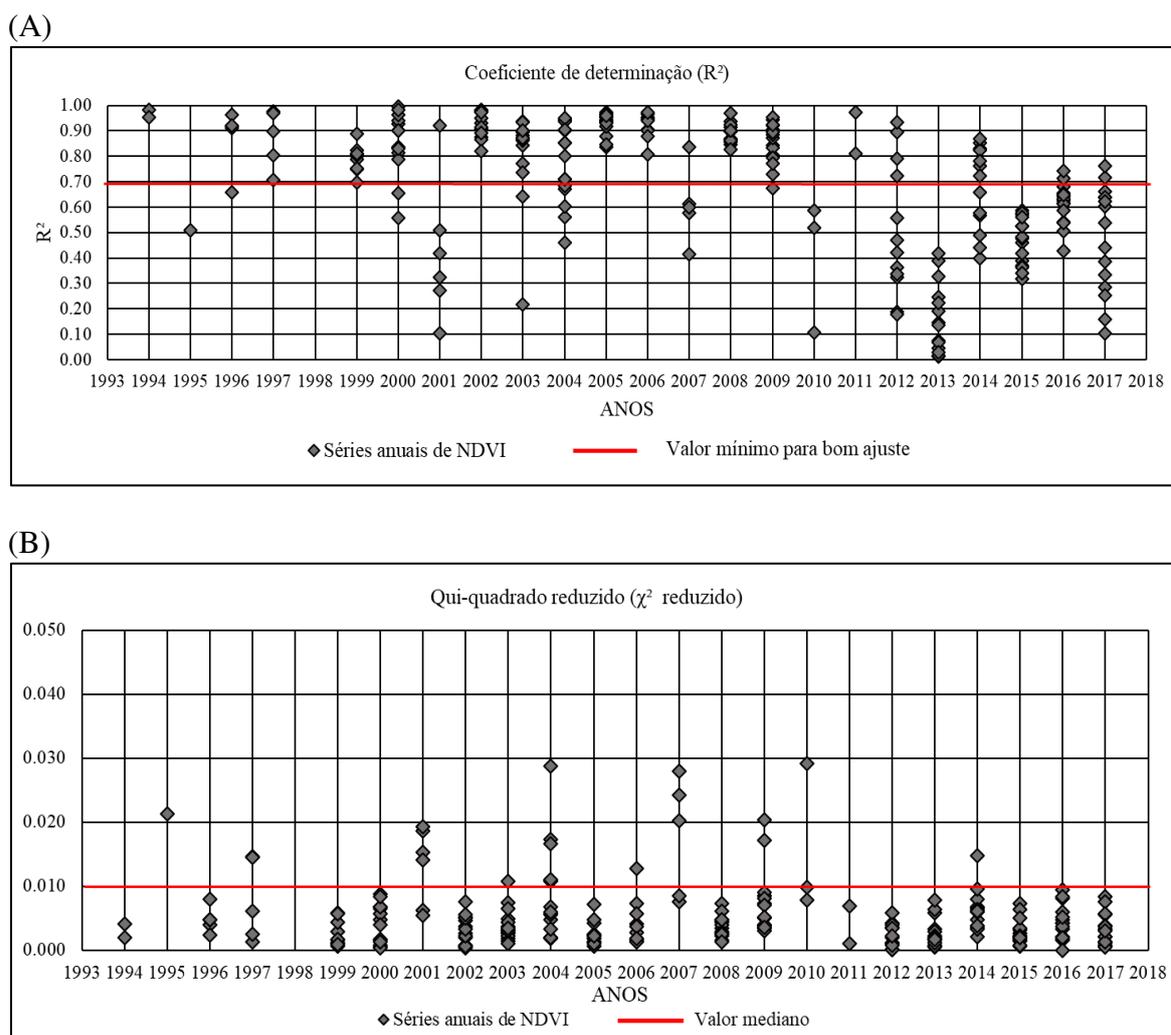
### 5.3. Aplicação do ajuste Cauchy

Para realização do ajuste nos 15 pontos onde ocorreu alteração antrópica, foi feita inicialmente uma análise das 360 séries de dados NDVI, onde 124 séries foram eliminadas,

sendo 58 séries de anos secos e 66 de anos chuvosos. Dessas séries, 88 apresentaram dados mal distribuídos e 36 possuíam tanto poucos dados como dados mal distribuídos. Então, 236 séries de dados de NDVI foram testadas no LAB FIT utilizando a função Cauchy como ajuste, das quais 108 (46%) correspondiam a anos secos e 128 (52%) a anos chuvosos.

Como os lançamentos dos satélites Landsat 7 e 8 só ocorreram em 1999 e 2013, respectivamente, a série de anos de 1994 a 1998 foi a que apresentou menor cobertura de satélite, com dados a cada 16 dias e, conseqüentemente, foi mais susceptível à eliminação por falta de dados ou dados mal distribuídos. Como exemplo, o ano de 1998 não apresentou nenhuma série que pudesse ser utilizada para o teste dos ajustes. Pode-se verificar o resultado desse ajuste a partir de uma análise multitemporal dos 15 pontos, utilizando o coeficiente de determinação  $R^2$  e qui-quadrado reduzido ( $\chi^2$  reduzido) como parâmetros estatísticos de avaliação, nas Figuras 12A e 12B, respectivamente.

**Figura 12** – Coeficiente de determinação ( $R^2$ ) e Qui-quadrado reduzido ( $\chi^2$  reduzido) e para as 236 séries de NDVI.

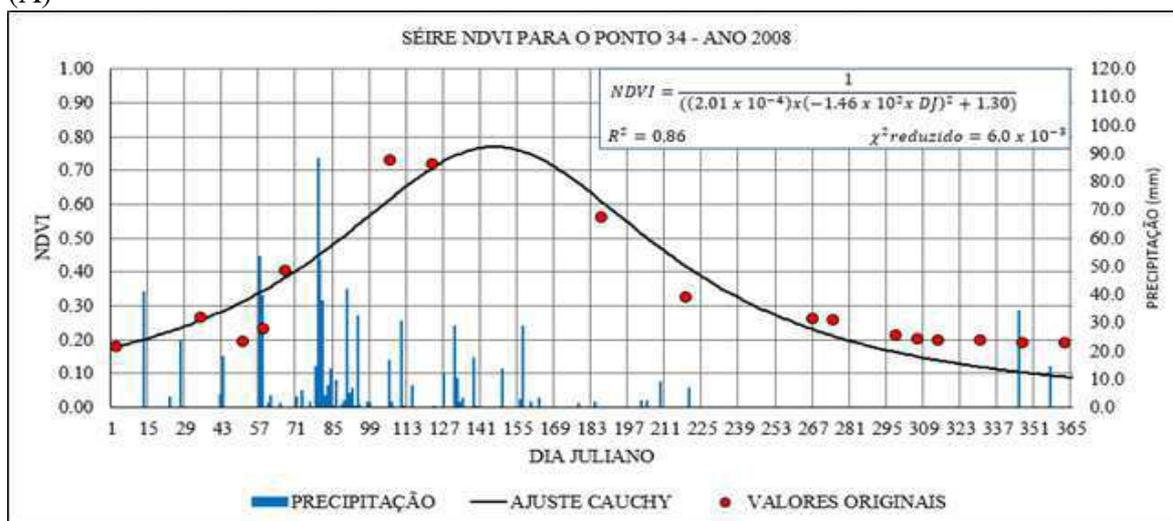


Fonte: Próprio autor.

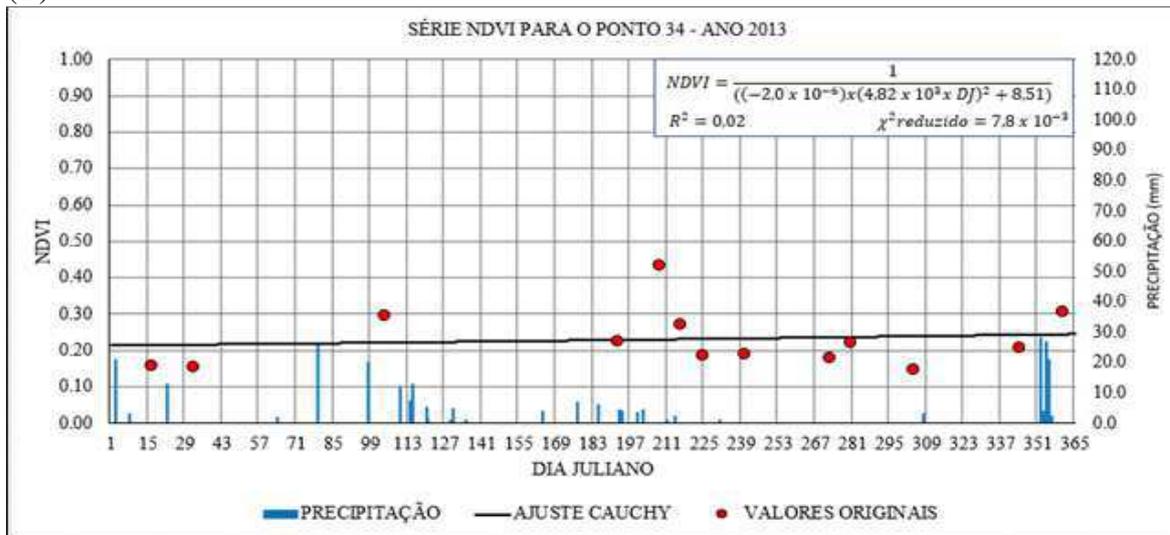
Verificou-se nos anos em que a precipitação estava abaixo da média (secos), que a função Cauchy não apresentou bom ajuste dos dados de NDVI, apresentando, na maioria das séries, valores de  $R^2$  abaixo de 0,70 (valor considerado neste estudo como mínimo para um bom ajuste), apresentando um coeficiente de determinação ( $R^2$ ) médio de 0,56 e  $\chi^2$  reduzido médio de  $4,3 \times 10^{-3}$ . Já para os anos chuvosos, a função obteve bom desempenho, sendo capaz de reconstruir as séries de NDVI com  $R^2$  atingindo valores de até 0,99, com valor médio de 0,82 e com qui-quadrado reduzido médio de  $5,6 \times 10^{-3}$ . Quando analisa-se o total de séries para cada tipo de ano (seco ou chuvoso), é possível perceber que a função não é eficiente para ajustar os dados nos anos secos, onde de 108 séries secas, apenas 37 obtiveram bom ajuste, o que corresponde a 34% do total de anos secos avaliados; por outro lado, de 128 séries chuvosas, 106 apresentaram bom ajuste, o que corresponde a 83% das séries chuvosas avaliadas. De maneira geral, das 236 series testadas, 143 (60%) apresentaram bom ajuste, das quais apenas 26% correspondem a anos secos e 74% a anos chuvosos. Os anos secos foram os responsáveis pela maioria das séries que não apresentaram bom ajuste. Para exemplificar essa análise, as Figuras 13A e 13B mostram ajustes para séries de NDVI de um ano chuvoso (A) e um ano seco (B), respectivamente.

**Figura 13** – Ajuste Cauchy para um ano típico seco (A) e chuvoso (B).

(A)



(B)



Fonte: Próprio autor.

Com a análise multitemporal desse índice é possível perceber que a curva que se assemelha a um sinal senoidal e que representa o comportamento da vegetação ao regime pluviométrico, sofre variações em decorrência do mesmo. Nos anos secos esse formato da curva deixa de existir (Figura 13B) e passa a ter um comportamento quase que linear, com valor médio de NDVI igual a 0,23, fazendo com que o ajuste Cauchy apresente baixo coeficiente de determinação ( $R^2 = 0,02$ ). O que indica que em anos secos, com chuvas abaixo da média, o ajuste Cauchy não é bom para reconstruir a série de NDVI, sendo necessário verificar outros ajustes específicos para esses anos.

Além disso, quanto mais sensível for a vegetação aos ciclos de chuva, ou seja, ampliar ou reduzir sua fotossíntese durante os períodos de chuva e estiagem, respectivamente, mais intensa se torna a relação do NDVI com a biomassa da vegetação. Essa característica é bem própria da Caatinga: durante o período chuvoso a vegetação aumenta sua folhagem, o que corresponde ao ganho de biomassa e elevação da atividade fotossintética, isso pode ser verificado pelo aumento do NDVI. No período seco, a vegetação reduz a fotossíntese, muitas vezes perdendo folhagem (redução da biomassa), o que é traduzido em valores baixos de NDVI. Esse ciclo anual de precipitação gera uma curva em forma de senóide para o NDVI, que pode ser verificada na Figura 13A, onde o índice atinge seu valor máximo próximo de 0,80.

A razão do ajuste Cauchy corresponder melhor aos dados de NDVI para os anos chuvosos pode ser explicado pelo fato de que a função traduz bem o comportamento senoidal gerado pelas variações na biomassa da vegetação ocasionadas pelo regime pluviométrico e que são indicadas pelos valores do NDVI, o que é esperado, pois esse índice está diretamente

relacionado com a atividade fotossintética da vegetação, uma vez que é formado por combinação linear da banda vermelha (RED) e do infravermelho próximo (NIR).

Segundo Jensen (2009), a reflectância no infravermelho próximo é diretamente proporcional ao crescimento da biomassa, enquanto a reflectância no vermelho (visível) é inversamente proporcional ao desenvolvimento do dossel das plantas, ficando comprovado, que associações através de combinações lineares dos dois valores de reflectância, apresentam respostas mais consistentes do estado da biomassa, do que a avaliação isolada de cada uma das reflectâncias.

Sendo assim, nos anos chuvosos em que a precipitação apresenta valores altos de NDVI nos 5 primeiros meses do ano e cai nos últimos 7 meses, a função é bem representada. Já para anos secos, a fotossíntese das plantas se encontra constante e em baixo nível, os valores de NDVI também permanecem quase que constantes e isso faz com que o ajuste Cauchy não tenha bom desempenho, tornando-se inadequado para preenchimento de falhas nesses anos.

Os resultados encontrados para o comportamento do NDVI estão de acordo com os identificados por Albuquerque *et al.* (2014), onde os autores encontraram mudanças significativas no NDVI entre os períodos secos e chuvosos, para uma área de Caatinga localizada no município de Sousa-PB.

Verifica-se na Figura 14 (de A até F) uma sequência de séries de NDVI no ponto 33 para alguns anos (2005-2009) onde houve alteração da cobertura ocasionada por ação antrópica no ano de 2006, segundo Cunha (2018). Verifica-se que mesmo no ano que ocorre a alteração e nos anos subsequentes, a curva continua se ajustando bem aos dados de NDVI, com exceção de 2007, ano seco após a mudança. Isso ocorre devido à existência de vegetação rasteira ou mesmo parte da vegetação natural que não foi totalmente alterada ou removida, ainda responde aos ciclos de precipitação, apresentando atividade fotossintética, sendo traduzida em valores de NDVI com o mesmo comportamento observado na vegetação preservada.

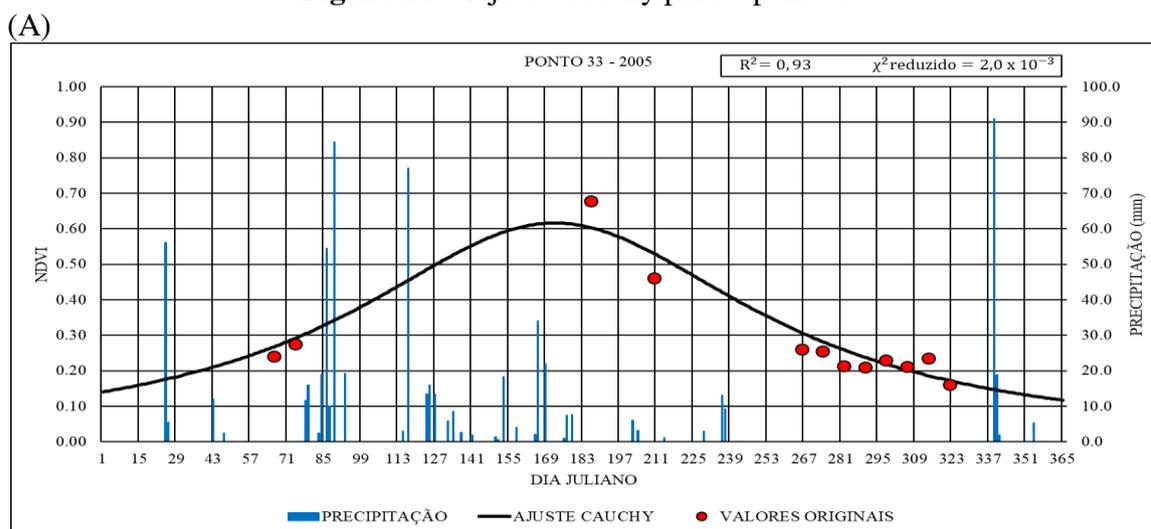
Dos 15 pontos onde ocorreu a mudança de cobertura, em apenas 7 a mudança ocorreu dentro do período analisado (94-2017), sendo possível a verificação do comportamento posterior a mudança apenas para esses pontos. Após as análises, pode ser verificado que o ajuste se manteve bom em 6 pontos (86%) após a mudança de cobertura e em apenas um ponto (28) não apresentou bom ajuste após a mudança (14%). No ponto 28 a mudança ocorreu em 2011 e, nos anos posteriores a mudança, apenas o ano de 2014 foi chuvoso (e foi descartado por possuir dados mal distribuídos), sendo os demais secos. Isso

influenciou o não ajuste após a mudança de cobertura, uma vez que a função não apresenta bom desempenho nos anos secos.

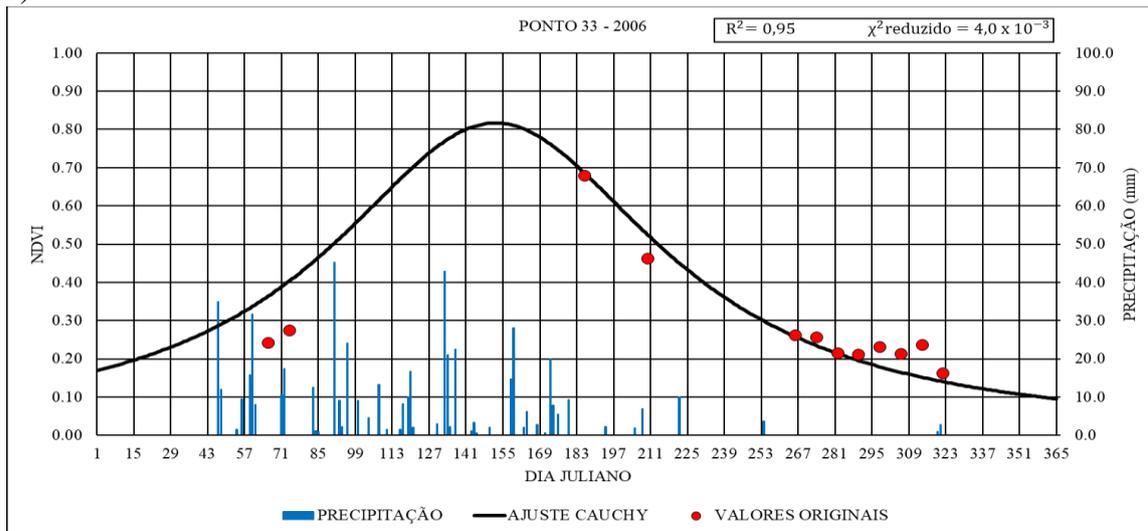
No estudo de Silva *et al.* (2018), os autores identificaram a partir de análises de séries temporais de NDVI para uma área de Caatinga no parque nacional da serra da capivara (estado do Piauí), que os valores de NDVI relativos à Caatinga quando analisados ao longo do tempo, são sazonais, mas não mostram nenhuma tendência, o que corrobora com o que foi identificado na análise multitemporal de NDVI realizada neste trabalho. Além disso, os autores mostraram que é possível isolar a sazonalidade da série, para estudos mais específicos da vegetação, para aplicação em processos de monitoramento, manejo e recuperação de áreas de Caatinga. Essa verificação fundamenta a essência deste trabalho, no que se refere ao fornecimento de uma ferramenta (série de NDVI reconstruída em escala diária) capaz de subsidiar essas aplicações.

Ainda no estudo de Silva *et al.* (2018), os autores concluíram que a variabilidade espacial e temporal detalhada no desenvolvimento da vegetação da Caatinga pode ser identificada usando dados Landsat TM e ETM + interpolados. O que indica que os dados utilizados para gerar a série de NDVI em escala diária para a área de Caatinga já foram utilizados em outros estudos e confirmados como eficientes em análises do desenvolvimento vegetal da Caatinga ao longo dos anos.

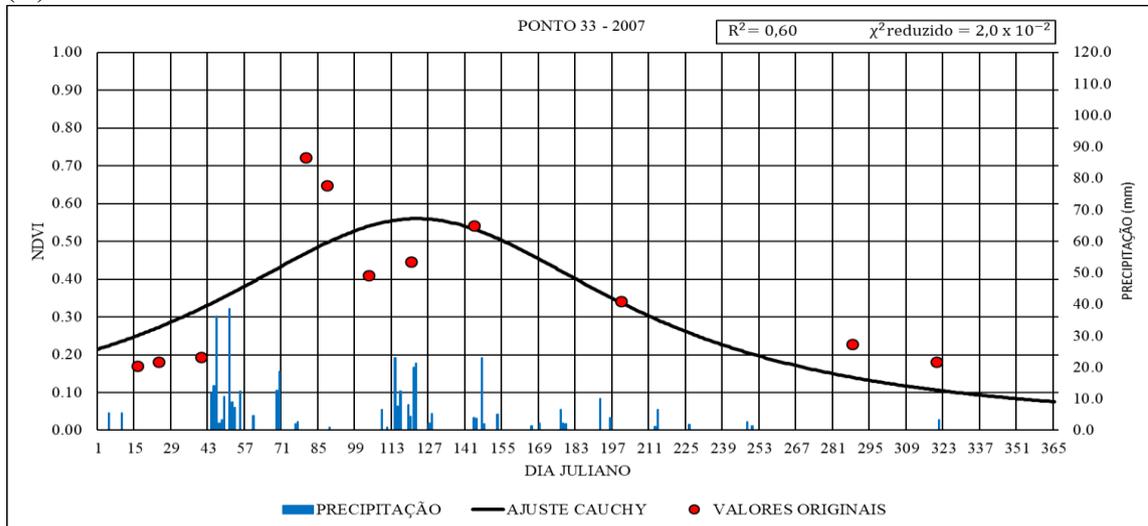
**Figura 14** – Ajuste Cauchy para o ponto 33.



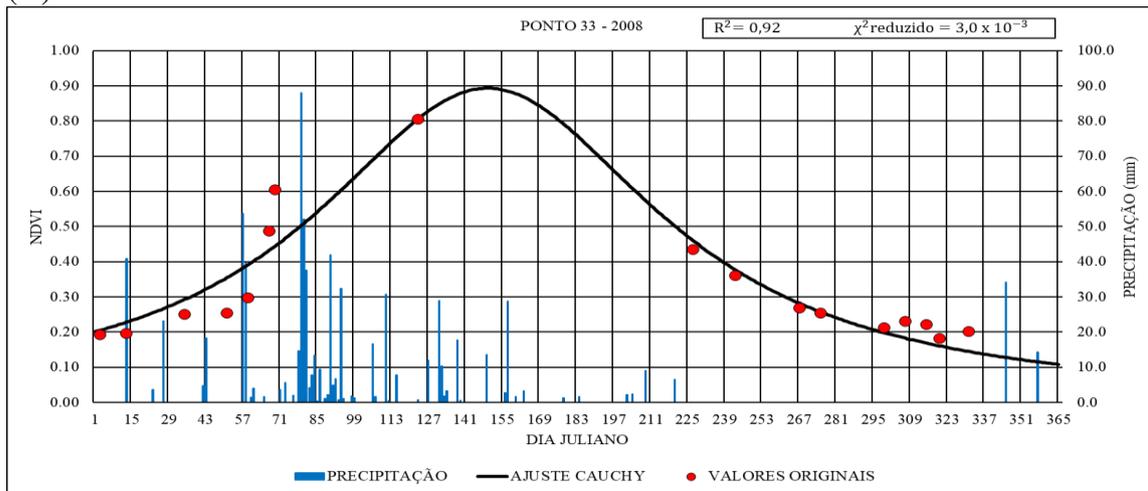
(B)

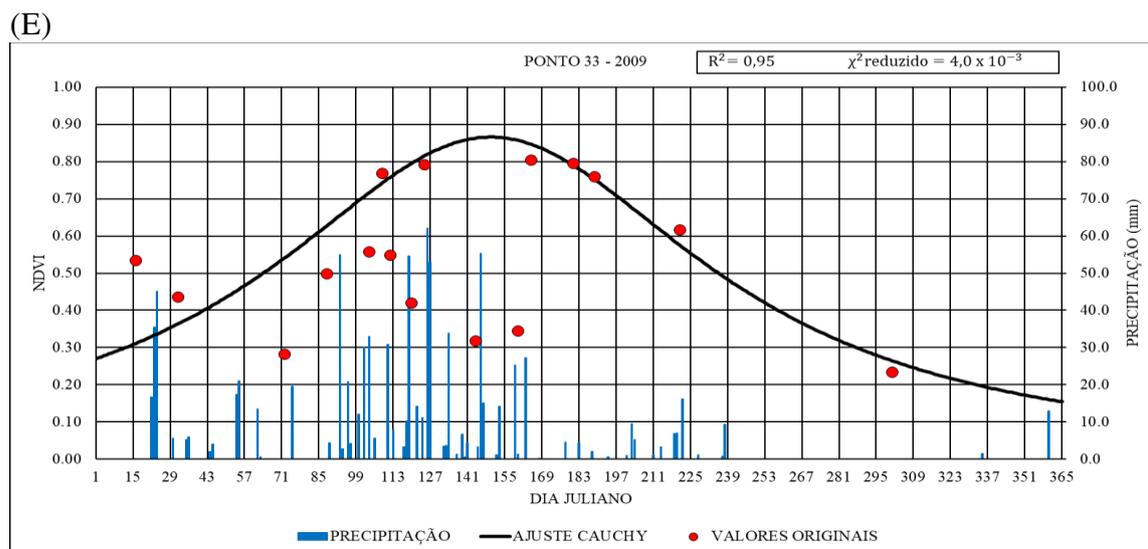


(C)



(D)





Fonte: Próprio autor.

Portanto, é perceptível a sensibilidade do NDVI à variação no regime pluviométrico da região, transformando o formato da curva do ajuste Cauchy conforme a precipitação. Contudo, ele não é sensível às mudanças de cobertura do solo, uma vez que seu comportamento permanece o mesmo tanto para áreas inalteradas como para aquelas que sofreram algum tipo de alteração causada por atividade humana, como desmatamento, queimadas ou mesmo pela agricultura e pecuária. Os gráficos dos demais pontos analisados podem ser verificados no Anexo I deste trabalho.

#### 5.4. Validação do ajuste

A partir da análise da Tabela 6, onde foram analisados dois pontos, sendo um de vegetação Caatinga preservada (ponto 6) e outro que sofreu alteração antrópica (ponto 33), pode ser verificado que os valores de RMSE não apresentaram grande variação para cada uma das funções, com diferença na maioria das séries na terceira casa decimal, o que implica que as funções se assemelham no ajuste das séries com relação ao RMSE.

**Tabela 6** — Erro Quadrático Médio da Raiz (RMSE) para as funções analisadas.

RMSE					
PONTO	ANO	CAUCHY	SG	AG	DL
	2002	0,04052	0,08074	0,04982	0,05531
	2003	0,03550	0,03197	0,03258	0,03259
6	2004	0,04914	0,05267	0,00909	0,00865
	2005	0,08236	0,06923	0,07423	0,19002
	2006	0,05189	0,03244	0,03044	0,03573

	2005	0,01524	0,04938	-	-
	2006	0,00001	0,05869	0,05125	0,02814
33	2007	0,09309	0,09377	0,09142	0,09983
	2008	0,04571	0,03615	0,03612	0,04279
	2009	0,05419	0,05417	0,01534	0,05102

Fonte: Próprio autor.

Ainda analisando a Tabela 6, pode-se notar que para a série do ano de 2005 (ponto 33), as funções AG e DL não conseguiram ajustar os dados, devido à baixa quantidade de valores de NDVI. O menor valor de RMSE (0,000013) foi obtido utilizando a função Cauchy para a série de valores de NDVI do ano 2006 (ponto 33).

De maneira geral, a função Assimétrica de Gauss (AG) obteve RMSE mais baixo quando comparado com os demais ajustes em 5 séries (50%), seguido de perto da função Cauchy que apresentou valor mais baixo de RMSE em 4 séries (40%), o filtro Savitzky-Golay apresentou valor mais baixo de RMSE em 3 séries (30%), enquanto a função Dupla Logística teve o pior desempenho entre as funções, obtendo valor mais baixo de RMSE apenas em uma série (10%). Esse resultado se assemelha ao encontrado por Julien e Sobrino (2018) no que se refere ao desempenho muito próximo das funções Cauchy e AG, tendo a função Assimétrica de Gauss apresentado ligeira vantagem em relação à análise do RMSE para as séries analisadas, contudo, ao levarmos em consideração os parâmetro estatístico avaliado inicialmente ( $\chi^2$  reduzido), a função Cauchy foi a melhor entre todas avaliadas, uma vez que a função AG também esteve presente no ranking de desempenho verificado na primeira etapa metodológica deste trabalho, e apresentou eficiência menor que a função Cauchy, com frequência de 54 % e  $\chi^2$  reduzido médio de  $6,69 \cdot 10^{-3}$ , sendo a terceira função nesse ranking, enquanto o ajuste Cauchy foi o melhor ajuste com frequência de 66% e  $\chi^2$  reduzido médio de  $5,07 \cdot 10^{-3}$ . Os valores originais de NDVI, bem como os valores obtidos com cada ajuste para as séries analisadas encontram-se indicados no ANEXO II deste trabalho.

## 6. CONCLUSÕES

. A função Cauchy apresentou bom ajuste, reconstruindo as séries de NDVI com valor médio do coeficiente de determinação  $R^2$  de 0,82, para anos chuvosos. As séries reconstruídas podem ser utilizadas em estudos mais específicos sobre a fenologia da Caatinga, o sequestro de carbono da vegetação e sua relação com as mudanças climáticas, já

que fornece informações em escala diária sobre o comportamento da vegetação e sua resposta aos eventos de precipitação. Para os anos secos a função Cauchy não apresentou bom ajuste, com baixo valor de  $R^2$  para a maioria dos pontos.

Uma limitação metodológica deste trabalho se refere ao limiar definido entre um bom ajuste e um ajuste ruim. Foi determinado que para séries com  $R^2$  abaixo de 0,70, o ajuste seria considerado ruim, pois uma série assim reconstruída não seria ideal para aplicação em estudos da relação vegetação-clima bem como em estudos fenológicos, para tanto seria necessário um ajuste que reconstruísse as séries com  $R^2$  acima de 70 %, representando os valores originais de forma mais fidedigna. Contudo, esse limiar foi definido sem referência na literatura e, portanto, pode ser reavaliado em outros estudos.

Em regiões com grande cobertura de nuvem durante a maior parte do ano, como a área de estudo deste trabalho, a obtenção de uma função matemática capaz de reconstruir séries temporais de NDVI, como a função Cauchy, se torna ferramenta essencial no estudo sobre os recursos naturais, uma vez que possibilitam quantificar e qualificar a biomassa e fornecer informações importantes a respeito do ciclo de crescimento e senescência da vegetação, ou seja, o entendimento de sua fenologia. Uma vez compreendido esse processo, modelos hidrológicos podem aproveitar as informações referentes à vegetação para simular de maneira mais fidedigna o balanço hídrico da área de estudo. Esta é a principal contribuição deste trabalho: fornecer uma ferramenta (séries de NDVI reconstruídas) que possibilite o estudo da vegetação Caatinga numa escala de tempo diária e sua relação com a variabilidade climática.

Além disso, esse tipo de abordagem pode auxiliar no desenvolvimento da agricultura de precisão, indicando os tempos de crescimento e senescência das culturas e facilitando o monitoramento das mesmas. E por fim, em regiões semiáridas que sofrem com a iminência de processos de desertificação, essa ferramenta pode auxiliar autoridades gestoras na análise de áreas mais susceptíveis (áreas com maior estresse hídrico), facilitando a tomada de decisões para mitigação dos efeitos desse fenômeno.

Para que essa ferramenta possa ser aplicada a outros estudos, como por exemplo, de mudanças de cobertura do solo, que requerem séries reconstruídas continuamente ao longo de vários anos, se faz necessário encontrar uma função que ajuste bem as séries de NDVI nos anos secos, agrupando para a série multitemporal duas funções, uma para ano chuvoso (Cauchy) e outra para o seco, possibilitando a análise contínua do dado.

As informações fornecidas aqui sobre as limitações no preenchimento de falhas em dados de sensoriamento remoto também podem ser importantes em relação aos esforços para

melhorar essa técnica e fornecer subsídios para estudos mais complexos da vegetação em escalas temporais e espaciais cada vez menores, na tentativa de entender e simular de maneira mais fidedigna possível os processos que ocorrem na natureza.

## REFERÊNCIAS BIBLIOGRÁFICAS

AESA– **Agência Executiva de Gestão das Águas do Estado da Paraíba**. Disponível em: <http://www.aesa.pb.gov.br/aesa-website/>. Acesso em 15 de junho de 2018.

ALBUQUERQUE, E. M. DE *et al.* Análise Do Comportamento Do Ndvi E NdwI Sob Diferentes Intensidades Pluviométricas No Município De Sousa-Pb. **Revista Estudos Geoambientais**, 2014.

ALVES, T. L. B. **Caracterização física e socioambiental da microbacia hidrográfica do riacho namorado no município de São João do Cariri-PB**. Dissertação de mestrado, 2012.

ANGELIS, C. F. **Princípios de Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais, Divisão de satélites e Sistemas Ambientais – INPE-DAS, 2011.

ATKINSON, P. M. *et al.* Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology. **Remote Sensing of Environment**, 2012.

ATZBERGER, C.; EILERS, P. H. C. A time series for monitoring vegetation activity and phenology at 10-daily time steps covering large parts of South America. **International Journal of Digital Earth**, 2011.

BARBOSA, A.H, KUMAR, L.V.T. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. **Journal of Arid Environments**, v.124, p.377-387, 2016.

BECK, P. S. A. *et al.* Improved monitoring of vegetation dynamics at very high latitudes: A new method using MODIS NDVI. **Remote Sensing of Environment**, 2006.

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

BIRTH, G. S.; MCVEY, G. Measuring the colour of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, n. 6, p. 640-643, 1968.

BOSCHETTI, L.; ROY, D. P.; JUSTICE, C. O.; HUMBER, M. L. MODIS – Landsat fusion for large area 30 m burned area mapping. **Remote Sensing of Environment**, v. 161, p. 27–42, 2015.

BRADLEY, B. A. *et al.* A curve fitting procedure to derive inter-annual phenologies from time series of noisy satellite NDVI data. **Remote Sensing of Environment**, 2007.

BRANDÃO, Z. N. *et al.* Agricultura de precisão para gerenciamento do algodão. In: AZEVÊDO, D. M. P.; BELTRÃO, N. E. M. **O agronegócio do algodão no Brasil**. Brasília: Embrapa Informação Tecnológica, 1309 p. cap. 20. v. 2, 2008.

BROOKS, E. B. *et al.* Fitting the multitemporal curve: A fourier series approach to the missing data problem in remote sensing analysis. **IEEE Transactions on Geoscience and Remote Sensing**, 2012.

CADIER, E.; FREITAS, B.J.; LEPRUN, J.C. **Bacia Experimental de Sumé: instalação e primeiros resultados**. Recife, SUDENE, 87p. (Série hidrológica, 16), 1983.

CAI, Z. *et al.* Performance of smoothing methods for reconstructing NDVI time-series and estimating vegetation phenology from MODIS data. **Remote Sensing**, 2017.

CAO, R. *et al.* A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. **Remote Sensing of Environment**, 2018.

CHEN, J. M.; DENG, F.; CHEN, M. Locally adjusted cubic-spline capping for reconstructing seasonal trajectories of a satellite-derived surface parameter. **IEEE Transactions on Geoscience and Remote Sensing**, 2006.

CHEN, J. *et al.* A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. **Remote Sensing of Environment**, 2004.

CHO, A. R.; SUH, M. S. Detection of contaminated pixels based on the short-term continuity of NDVI and correction using spatio-temporal continuity. **Asia-Pacific Journal of Atmospheric Sciences**, 2013.

COELHO, V. H. R. *et al.* Dinâmica do uso e ocupação do solo em uma bacia hidrográfica do semiárido brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2014.

CUNHA, J. E. B. L. **Monitoramento ambiental por sensoriamento remoto: avaliação, automação e aplicação ao bioma Caatinga utilizando séries históricas Landsat**. Tese de doutorado, 2018.

DI VITTORIO, A.C., GEORGAKAKOS, P.A. Land cover classification and wetland inundation mapping using MODIS. **Remote Sensing of Environment**, v.204, p.1-17, 2018.

ERNST, S.; LYMBURNER, L.; SIXSMITH, J. Implications of Pixel Quality Flags on the Observation Density of a Continental Landsat Archive. **Remote Sensing**, 2018.

FOGA, S. *et al.* Cloud detection algorithm comparison and validation for operational Landsat data products. **Remote Sensing of Environment**, 2017.

GATES, D.M. *et al.* Spectral properties of plants. **Applied Optics**, 4(1): 11-20, 1965.

GENG, M. *et al.* Comparison of eight techniques for reconstructing multi-satellite sensor time-series NDVI data sets in the Heihe river basin, China. **Remote Sensing**, 2014.

HABOUDANE, D. *et al.* Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, n. 3, p. 337-352, 2004.

HIGGINBOTTOM, T. P.; SYMEONAKIS, E. Assessing land degradation and desertification using vegetation index data: Current frameworks and future directions. **Remote Sensing**, v. 6, n. 10, p. 9552–9575, 2014.

HIRD, J. N.; MCDERMID, G. J. Noise reduction of NDVI time series: An empirical comparison of selected techniques. **Remote Sensing of Environment**, 2009.

HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, 1986.

HOUBORG, R., *et al.* Advances in remote sensing of vegetation function and traits. **International Journal Applied Earth Observations and Geoinformation**, v.43, p. 1-6, 2015.

HUETE, A. R. A soil adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295-309, 1988.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440-451, 1997.

IBGE – **Instituto Brasileiro de Geografia e Estatística**. Disponível em: <http://www.ibge.gov.br/>. Acesso em 15 de dezembro de 2018.

IBRAHIM, Y. Z. *et al.* Land degradation assessment using residual trend analysis of GIMMS NDVI3g, soil moisture and rainfall in Sub-Saharan West Africa from 1982 to 2012. **Remote Sensing**, v. 7, n. 5, p. 5471–5494, 2015.

JEGANATHAN, C.; NISHANT, N. Scrutinising MODIS and GIMMS Vegetation Indices for Extracting Growth Rhythm of Natural Vegetation in India. **Journal of the Indian Society of Remote Sensing**, 2014.

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

JIA, K. *et al.* Land cover classification of landsat data with phenological features extracted from time series MODIS NDVI data. **Remote Sensing**, 2014.

JONES, G.H.; VAUGHAN, A.R. **Remote sensing of vegetation: Principles, Techniques and Applications**. New York, EUA: OXFORD UNIVERSITY PRESS, 2010.

JÖNSSON, P.; EKLUNDH, L. Seasonality extraction by function fitting to time-series of satellite sensor data. **IEEE Transactions on Geoscience and Remote Sensing**, 2002.

JÖNSSON, P.; EKLUNDH, L. TIMESAT - A program for analyzing time-series of satellite sensor data. **Computers and Geosciences**, 2004.

JULIEN, Y.; SOBRINO, J.A. Optimizing and comparing gap-filling techniques using simulated NDVI time series from remotely sensed global data. **International Journal of Applied Earth Observation and Geoinformation**, 2019.

JULIEN, Y.; SOBRINO, J. A. TISSBERT: A benchmark for the validation and comparison of NDVI time series reconstruction methods. **Revista de Teledetección**, [S.l.], n. 51, p. 19-31, 2018.

JULIEN, Y.; SOBRINO, J. A. Comparison of cloud-reconstruction methods for time series of composite NDVI data. **Remote Sensing of Environment**, 2010.

KANDASAMY, S. *et al.* A comparison of methods for smoothing and gap filling time series of remote sensing observations – application to MODIS LAI products. **Biogeosciences**, v.10, p. 4055–4071, 2013.

KE, L.; DING, X.; SONG, C. Reconstruction of time-series modis lst in central qinghai-tibet plateau using geostatistical approach. **IEEE Geoscience and Remote Sensing Letters**, 2013.

KUPLICH, T. M.; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2013.

LAGO, W. N. M. *et al.* Ocupação e adequação do uso das terras na microbacia do Ribeirão Extrema, Distrito Federal: Parte I. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2012.

LEAL, I.R. *et al.* Changing the course of biodiversity conservation in the Caatinga of Northeastern Brazil. **Conservation Biology**. v.19, p.701-706, 2005.

LEROUX, L. *et al.* Driving forces of recent vegetation changes in the Sahel: Lessons learned from regional and local level analyses. **Remote Sensing of Environment**, v. 191, p. 38–54, 2017.

LI, G. *et al.* Response of evapotranspiration to changes in land use and land cover and climate in China during 2001–2013. **Science of the Total Environment**, v.596–597, p. 256-265, 2017.

LIN, C. H. *et al.* Patch-based information reconstruction of cloud-contaminated multitemporal images. **IEEE Transactions on Geoscience and Remote Sensing**, 2014.

LIU, R. *et al.* Global evaluation of gap-filling approaches for seasonal NDVI with considering vegetation growth trajectory, protection of key point, noise resistance and curve stability. **Remote Sensing of Environment**, 2017.

LOURENÇO, V. R. *et al.* Análise temporal do NDVI sob condições de caatinga preservada. **In III INOVAGRI INTERNATIONAL MEETING**, Fortaleza. P.808 – 814, 2015.

LU *et al.* Land cover change detection by integrating object-based data blending model of Landsat and MODIS. **Remote Sensing of Environment**, v.184, p.374-386, 2016.

MARIANO, D. A. *et al.* Use of remote sensing indicators to assess effects of drought and human-induced land degradation on ecosystem health in Northeastern Brazil. **Remote Sensing of Environment**, v. 213, p. 129-143, 2018.

MARKERT, K. *et al.* Historical and Operational Monitoring of Surface Sediments in the Lower Mekong Basin Using Landsat and Google Earth Engine Cloud Computing. **Remote Sensing**, 2018.

MATSUSHITA, B.; XU, M.; FUKUSHIMA, T. Characterizing the changes in landscape structure in the Lake Kasumigaura, Japan using a high-quality GIS dataset. **Landscape and Urban Planning**, v.78, p.241-250, 2006.

MCCLOY, K. R.; LUCHT, W. Comparative evaluation of seasonal patterns in long time series of satellite image data and simulations of a global vegetation model. **IEEE Transactions on Geoscience and Remote Sensing**, 2004.

MELAAS, E. K.; FRIEDL, M. A.; ZHU, Z. Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM+ data. **Remote Sensing of Environment**, 2013.

MENDOZA, F.M. *et al.* Analysing land cover and land use change processes at watershed level: A multitemporal study in the Lake Cuitzeo Watershed, Mexico (1975–2003). **Applied Geography**, v.31, p.237-250, 2011.

MIGLANI, A. *et al.* Comparasion of two data smoothing techniques for vegetation spectra derived from EO-1 Hyperion. **Journal of the Indian Society of Remote Sensing**, v.39, n.4, p. 443–453, 2011.

MICHISHITA, R. *et al.* Empirical comparison of noise reduction techniques for NDVI time-series based on a new measure. **ISPRS Journal of Photogrammetry and Remote Sensing**, 91, 17-28, 2014.

MONDAL, S. *et al.* Time-series cloud noise mapping and reduction algorithm for improved vegetation and drought monitoring. **GIScience and Remote Sensing**, 2017.

MORAES, E. C. Curso de Inteligência Tecnológica - Fundamentos de Sensoriamento Remoto. INPE, 2002.

MORENO, A. *et al.* Noise Reduction and Gap Filling of fAPAR Time Series Using an Adapted Local Regression Filter. **Remote Sensing**, 2014.

MOTOHKA, T. *et al.* Evaluation of sub-pixel cloud noises on MODIS daily spectral indices based on in situ measurements. **Remote Sensing**, v.3, n.8, p. 1644–1662, 2011.

MOURA, G. S. S. Uso de imagens TM/Landsat-5 na avaliação da degradação ambiental e riscos a desastres ENSO, no Município de Sumé –PB. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, 16-21, INPE, p. 205-212. 2005.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Universidade Federal de Viçosa, 3ª edição, Ed. UFV, 315 p., 2007.

NOVO, M. FL.; PONZONI, J. **INTRODUÇÃO AO SENSORIAMENTO REMOTO**. Dados, 2001.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo, Terceira Edição. Editora Edgard Blucher, 2008.

PASTOR-GUZMANA, J., DASHA, J., ATKINSON, M. P. Remote sensing of mangrove forest phenology and its environmental drivers. **Remote Sensing of Environment**, v. 205, p. 71-84, 2018.

POTAPOV, P.; TURUBANOVA, S.; HANSEN, M. C. Regional-scale boreal forest cover and change mapping using Landsat data composites for European Russia. **Remote Sensing of Environment**, 2011.

POTTER, C. *et al.* Major disturbance events in terrestrial ecosystems detected using global satellite data sets. **Global Change Biology**, 2003.

ROERINK, G. J.; MENENTI, M.; VERHOEF, W. Reconstructing cloudfree NDVI composites using Fourier analysis of time series. **International Journal of Remote Sensing**, 2000.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, v. 51, n. 3, p. 375-384, 1995.

ROUSE, J. W. *et al.* Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. Texas: **Texas A&M University**, 1974.

SAVITZKY, A.; GOLAY, M.J.E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, v.36, n.8, pp. 1627- 1639, 1964.

SCHULZ, C. *et al.* Land change and loss of landscape diversity at the Caatinga phytogeographical domain – Analysis of pattern-process relationships with MODIS land cover products (2001–2012). **Journal of Arid Environments**, v.136, p.54-74, 2017.

SHIRATSUCHI, L. S. *et al.* Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. *In: Agricultura de precisão: resultados de um novo olhar*, 2014.

SILVA, S.V.D.; CRUZ, M.B.C. Tipologias de Caatinga: Uma Revisão em Apoio a Mapeamentos Através de Sensoriamento Remoto Orbital e GEOBIA. **Revista do departamento de Geografia**, V.35, USP, 2018.

SILVA, C. R. DA *et al.* Analysis of the phenology dynamics of Brazilian caatinga species with NDVI time series. **Cerne**, 2018.

SILVA, S.R. *et al.* Patterns of Cactaceae Species Distribution in A Protected Area in the Semiarid Caatinga Biome of North-Eastern Brazil. **Edinburgh Journal of Botany**. v.73, p.157-170, 2016.

SILVA, P.W. DA *et al.* “LAB Fit Ajuste de Curvas”: Um software em português para tratamento de dados experimentais. **Revista Brasileira de Ensino de Física**, 2004.

SOUZA, R. *et al.* Vegetation response to rainfall seasonality and interannual variability in tropical dry forests. **Hydrological processes**, 2016.

SPANNER, M. A. *et al.* The seasonality of AVHRR data of temperate coniferous forests: Relationship with leaf area index. **Remote Sensing of Environment**, 1990.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

USGS. **Landsat Surface Reflectance Quality Assessment/Landsat Missions**. Disponível em: <<https://landsat.usgs.gov/landsat-surface-reflectance-quality-assessment/>> Acesso em: 17 de dezembro de 2018.

VANZELA, L. S.; HERNANDEZ, F. B. T.; FRANCO, R. A. M. Influência do uso e ocupação do solo nos recursos hídricos do Córrego Três Barras, Marinópolis. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2010.

VELLEMAN, P. F. Definition and a comparison of robust nonlinear data smoothing algorithms. **Journal of the American Statistical Association**, 1980.

VERBESSELT, J. *et al.* Remotely sensed resilience of tropical forests. **Nature Climate Change**, 2016.

WILLSTATTER, R.; STOOLL, A. **Untersuchungen über die assimilation der kohlenzure**. Springer, Berlin, 1918.

WORKIE, G.T., DEBELLA, J.H. Climate change and its effects on vegetation phenology across ecoregions of Ethiopia. **Global Ecology and Conservation**, 2018.

XIAO, Z. *et al.* Reconstruction of satellite-retrieved land-surface reflectance based on temporally-continuous vegetation indices. **Remote Sensing**, 2015.

XU, L. *et al.* A temporal-spatial iteration method to reconstruct NDVI time series datasets. **Remote Sensing**, 2015.

YANG, G. *et al.* A moving weighted harmonic analysis method for reconstructing high-quality SPOT VEGETATION NDVI time-series data. **IEEE Transactions on Geoscience and Remote Sensing**, 2015.

ZHANG, Q. *et al.* Vegetation phenology on the Qinghai-Tibetan Plateau and its response to climate change (1982–2013). **Agricultural and Forest Meteorology**, 2018.

ZHOU, J.; JIA, L.; MENENTI, M. Reconstruction of global MODIS NDVI time series: Performance of Harmonic ANalysis of Time Series (HANTS). **Remote Sensing of Environment**, 163, 217-228. 2015.

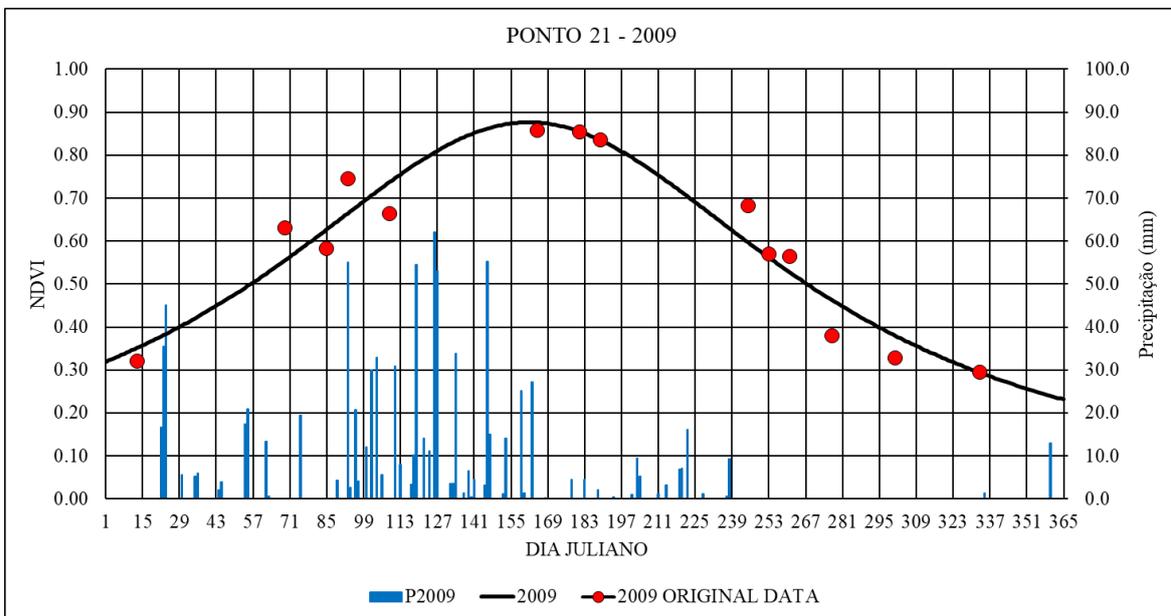
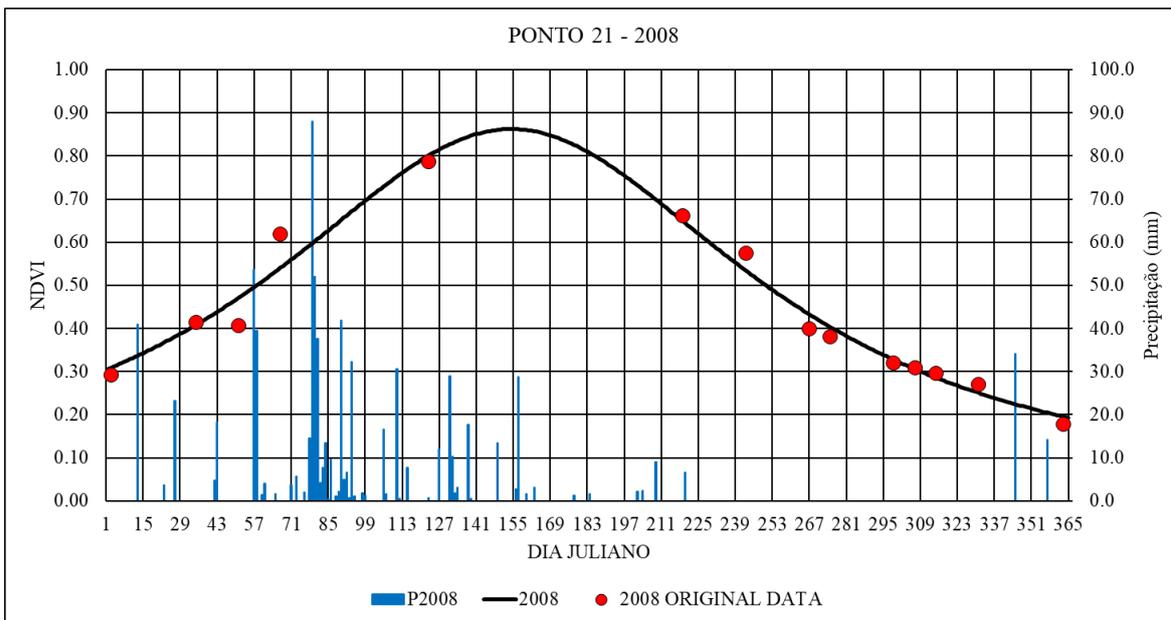
ZHU, W. *et al.* A changing-weight filter method for reconstructing a high-quality NDVI time series to preserve the integrity of vegetation phenology. **IEEE Transactions on Geoscience and Remote Sensing**, 2012.

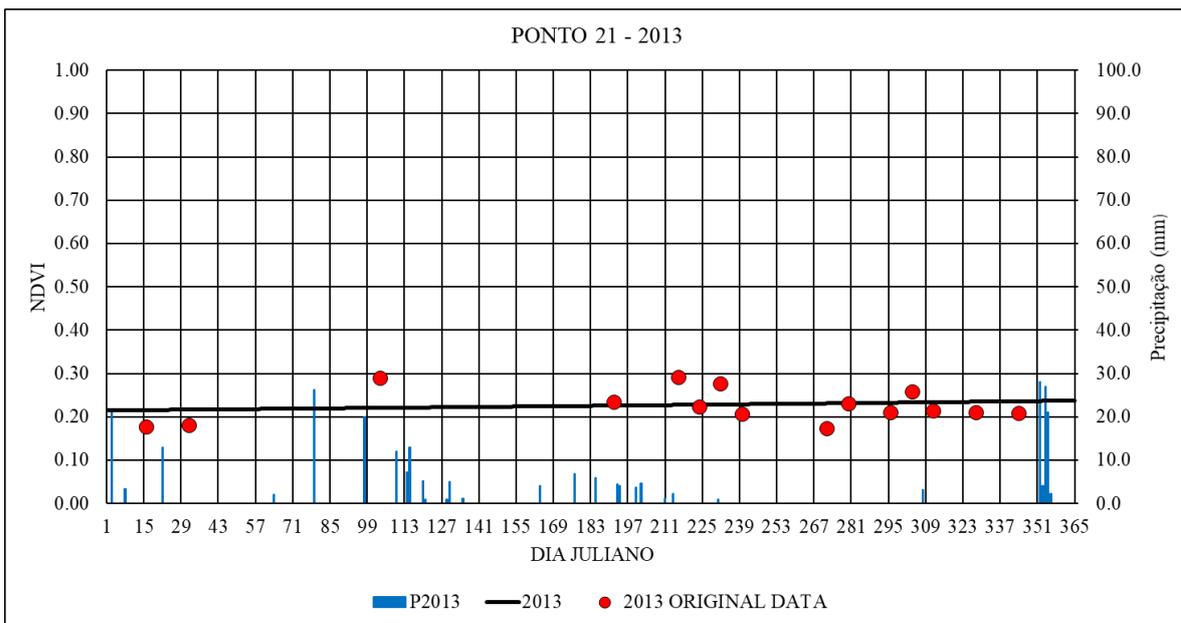
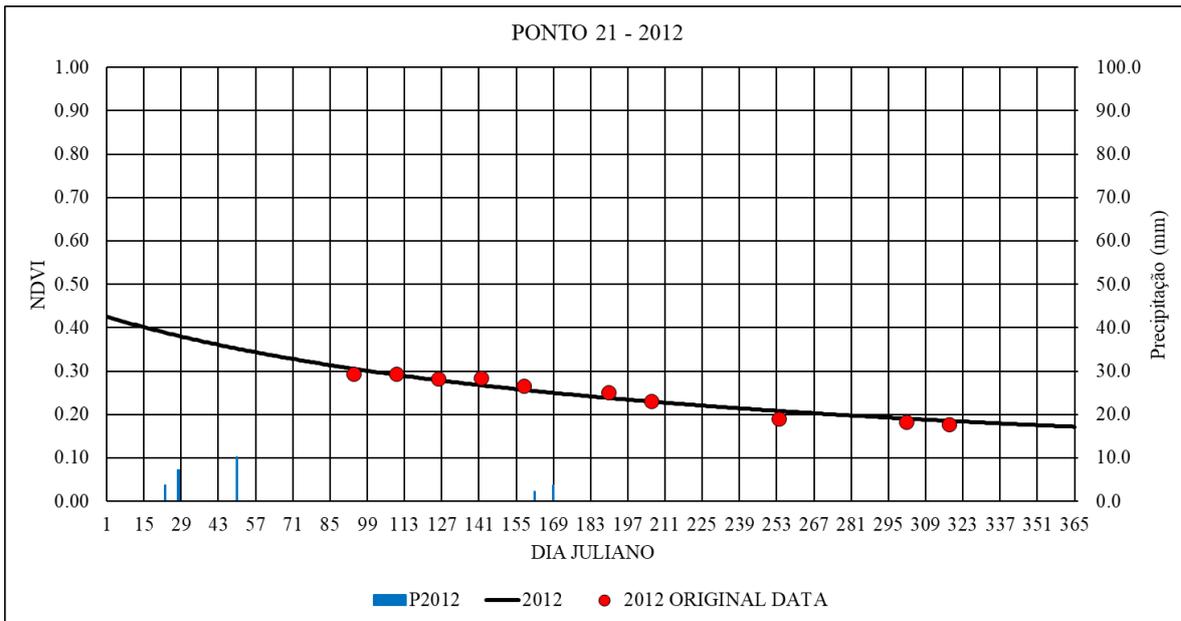
## **ANEXOS**

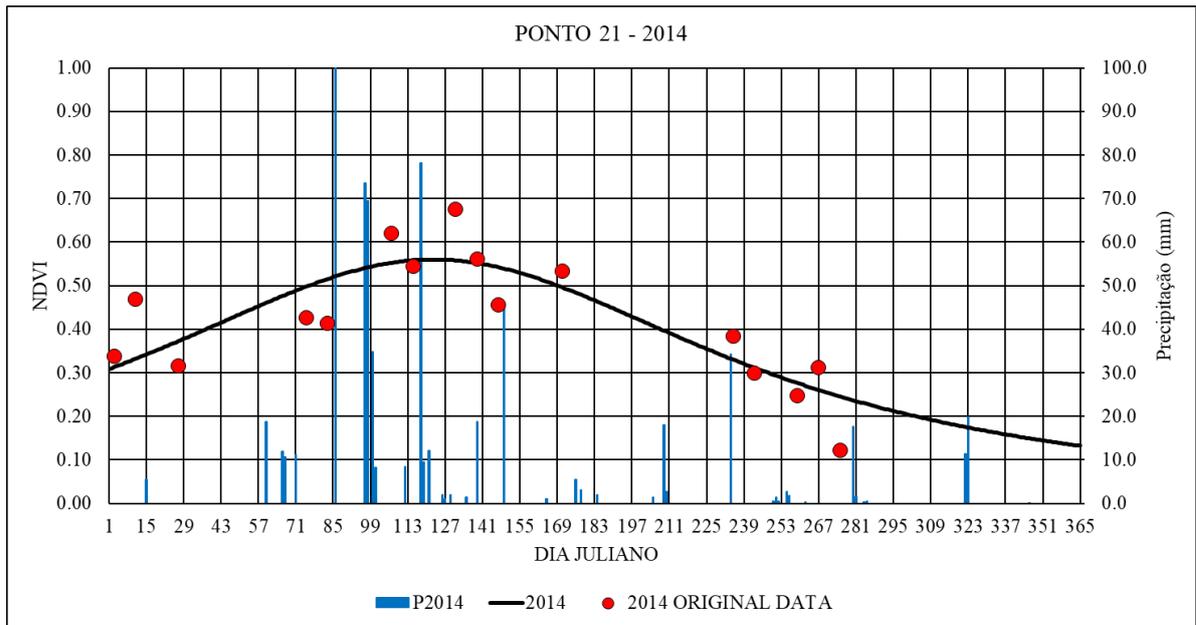
## ANEXO I – GRÁFICOS DO AJUSTE CAUCHY PARA O NDVI

### • PONTOS QUE SOFRERAM ALTERAÇÃO ANTRÓPICA

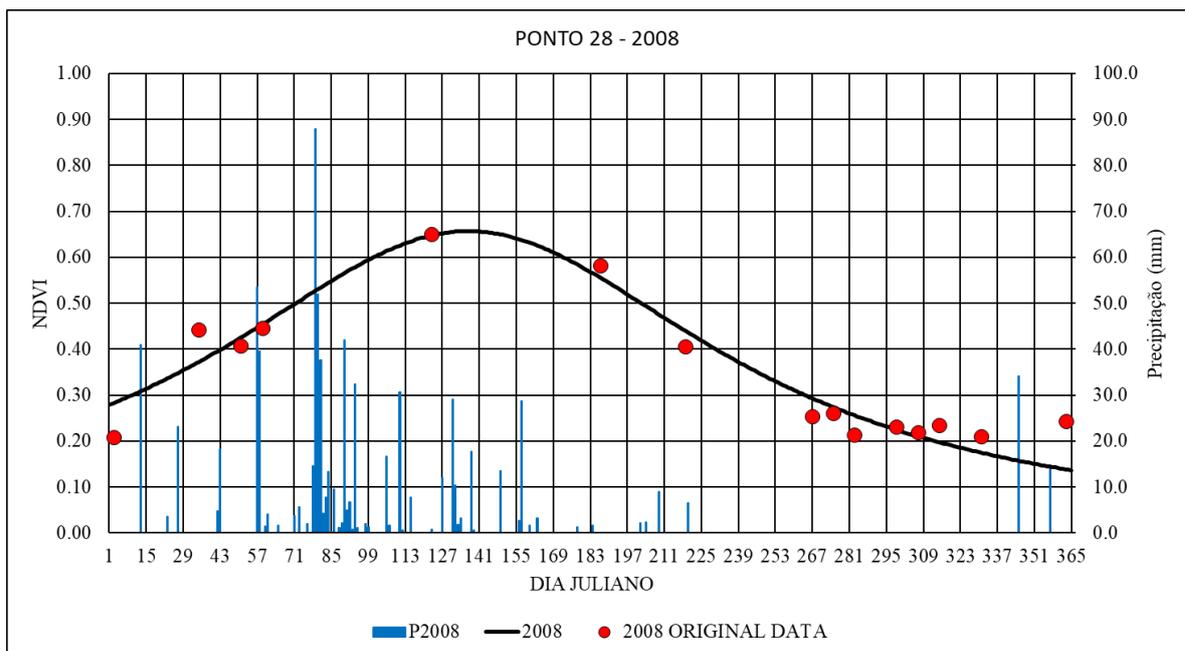
#### PONTO 21

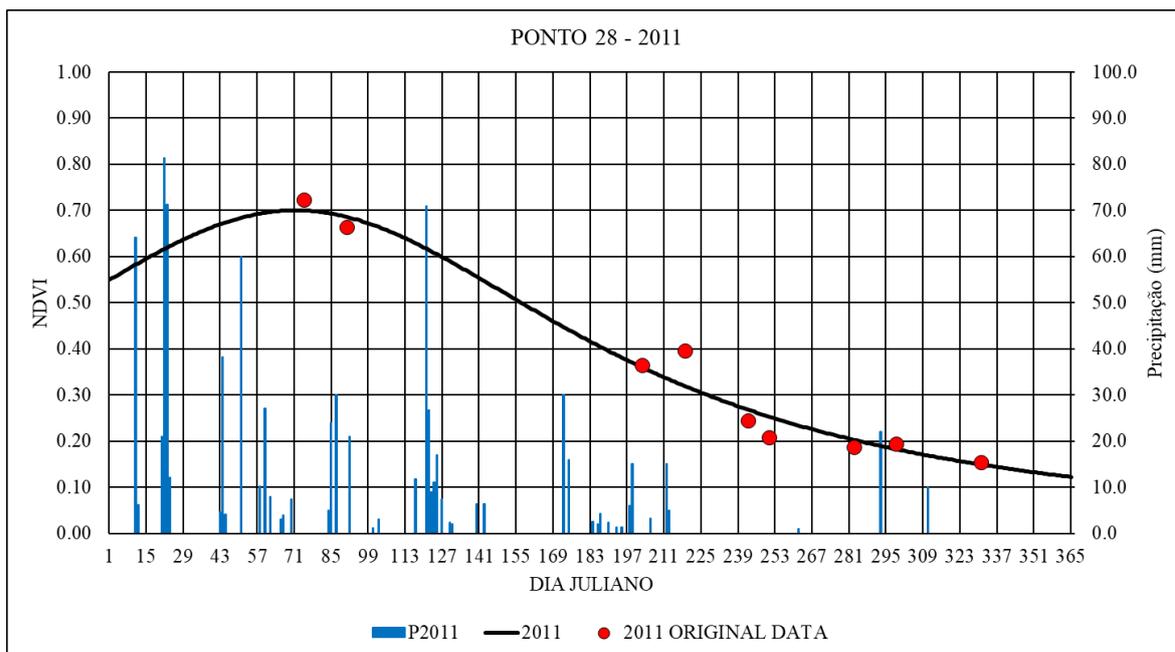
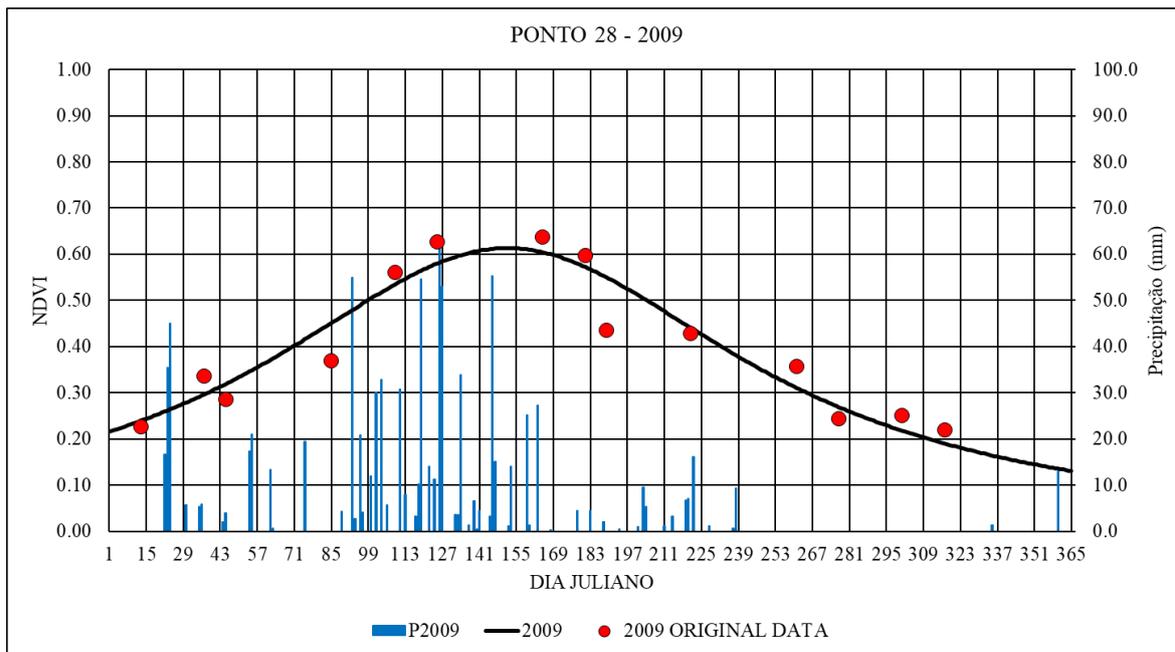


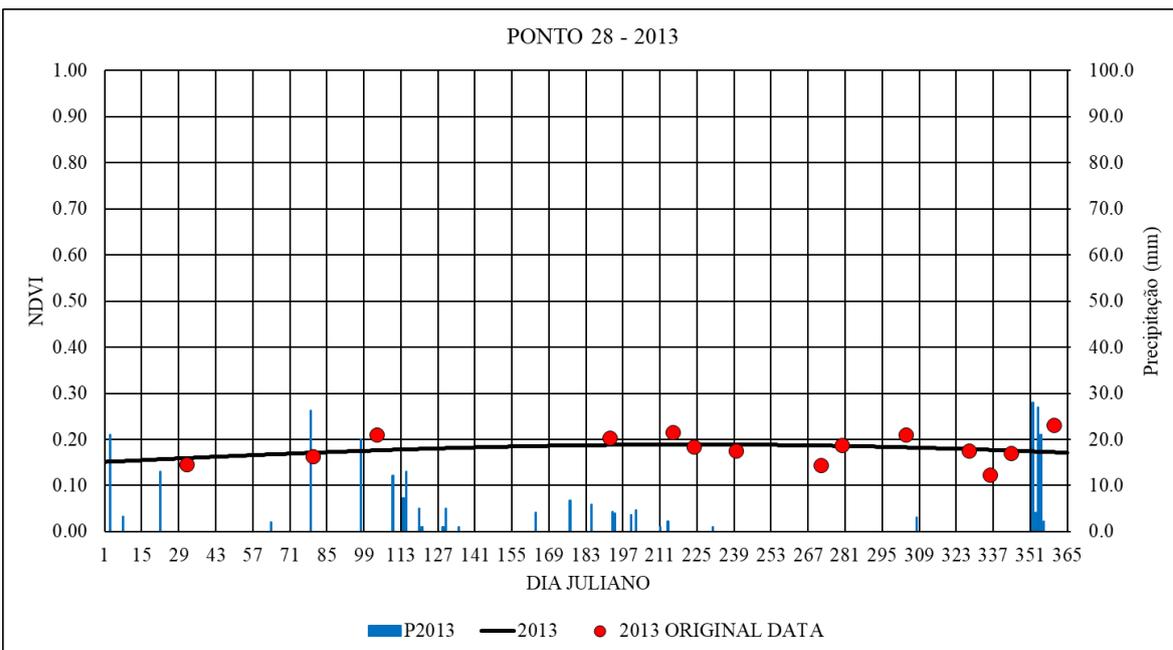
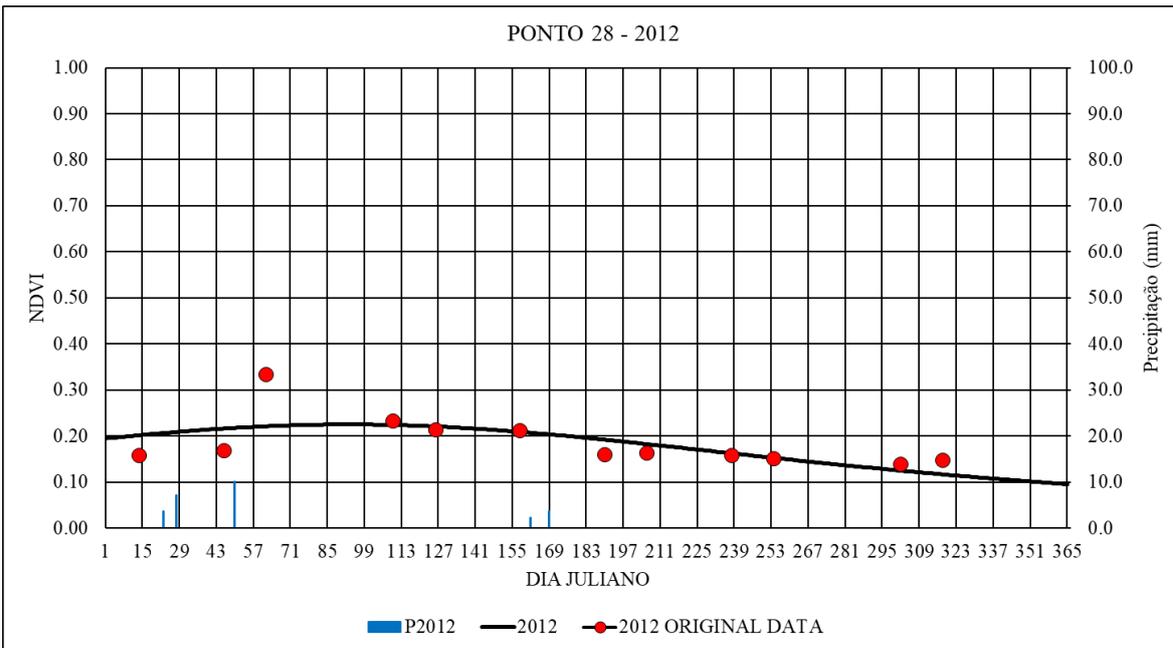


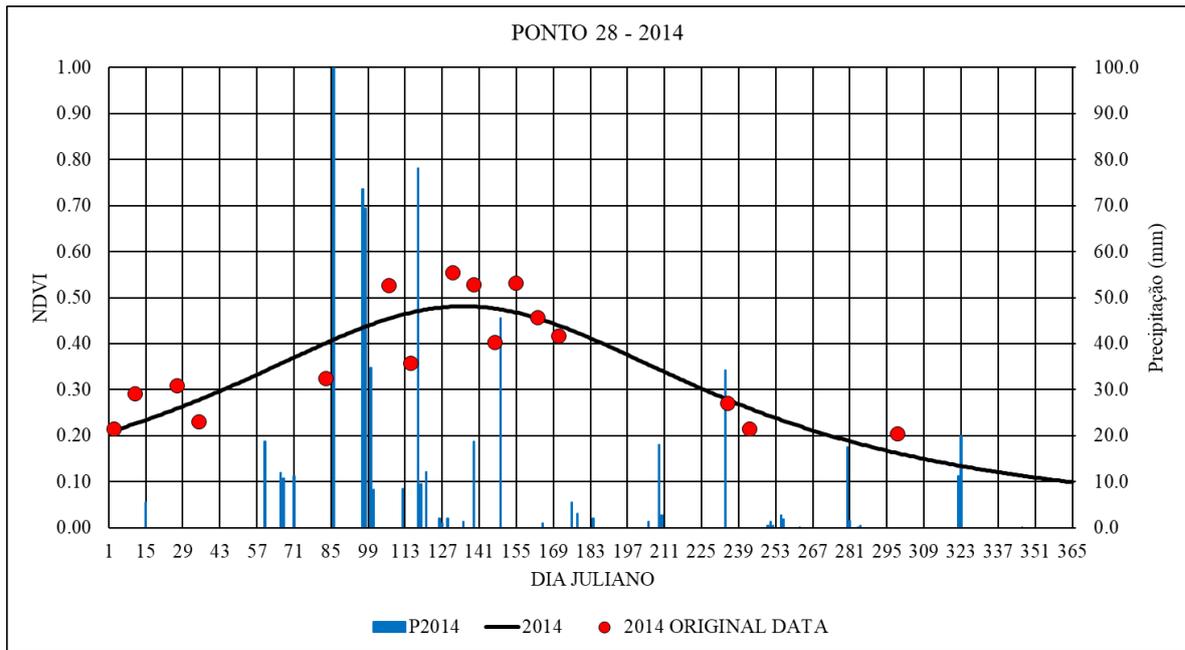


### PONTO 28

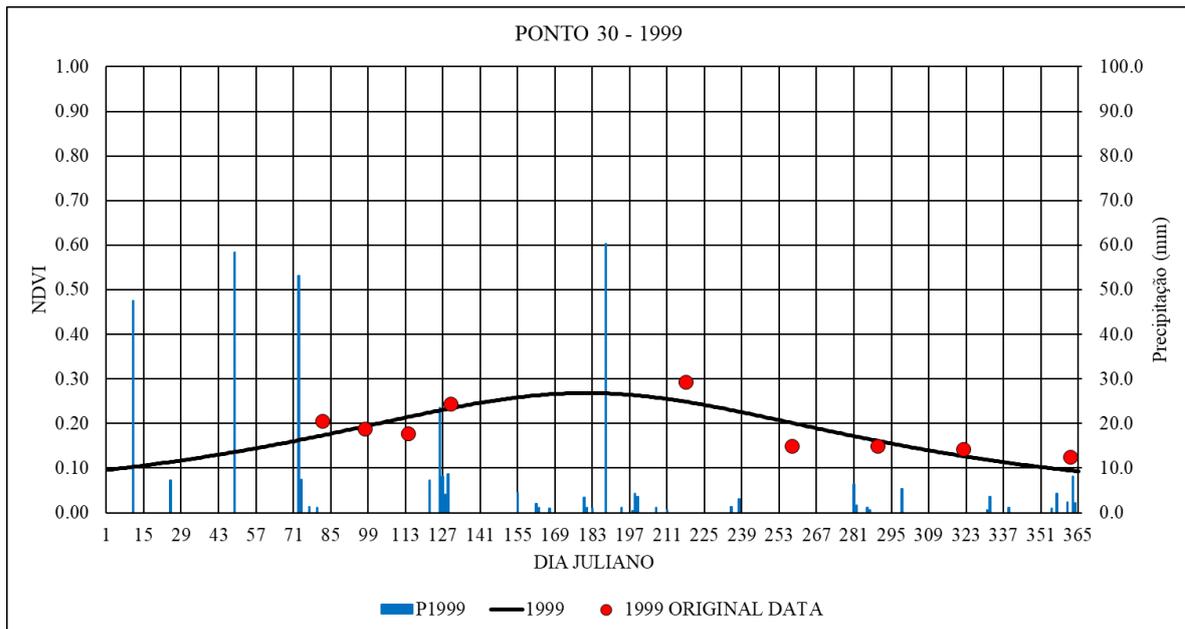


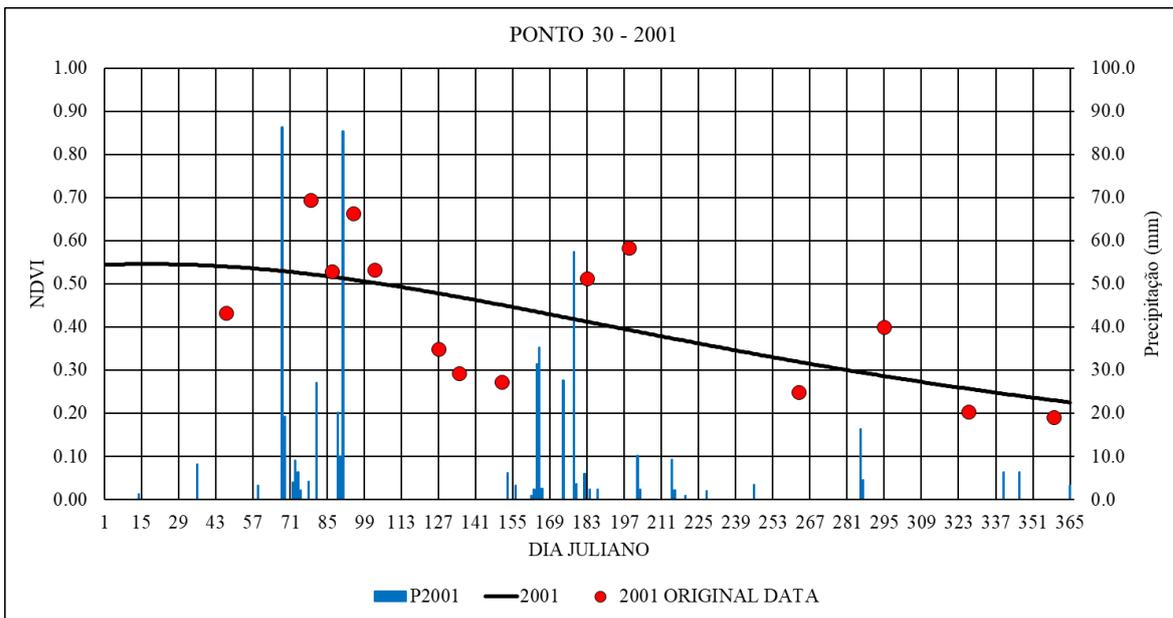
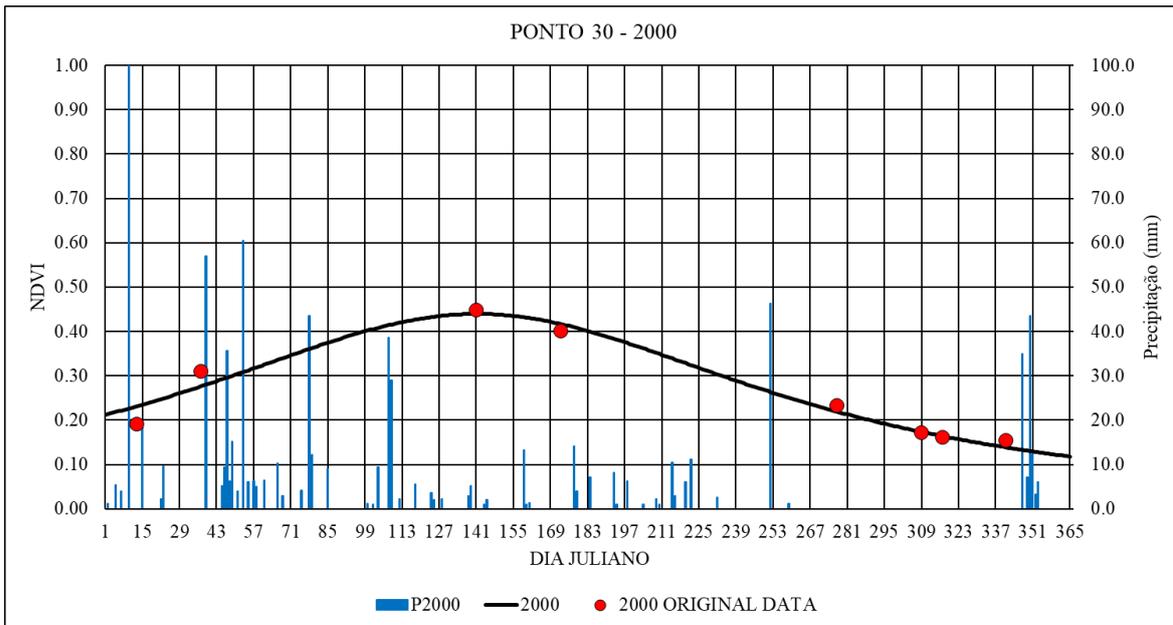


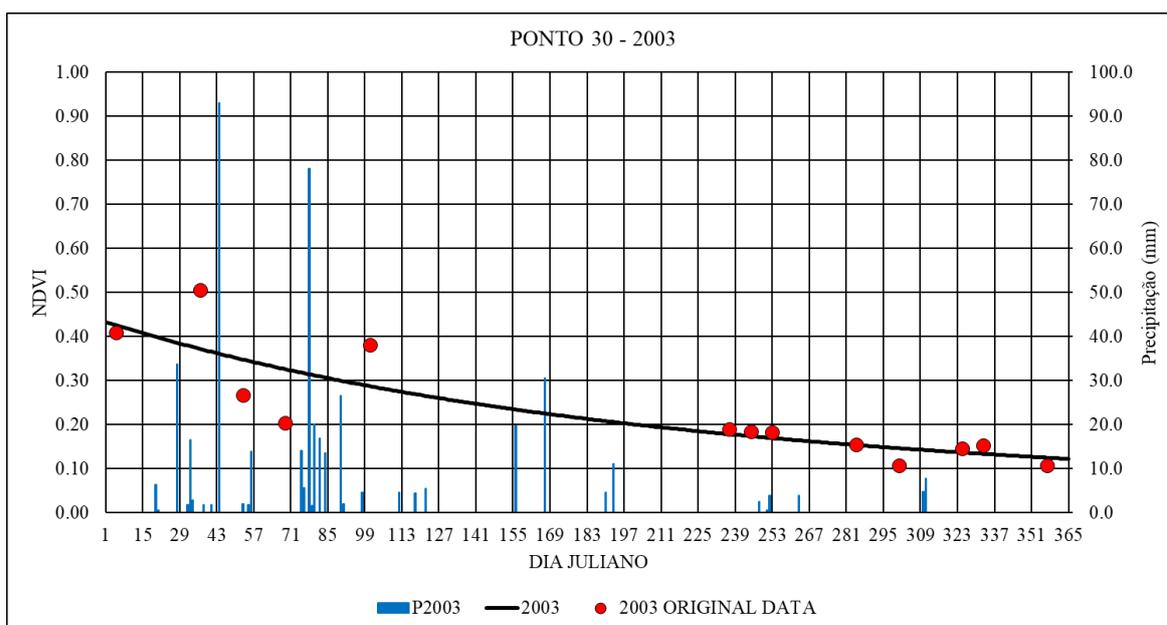
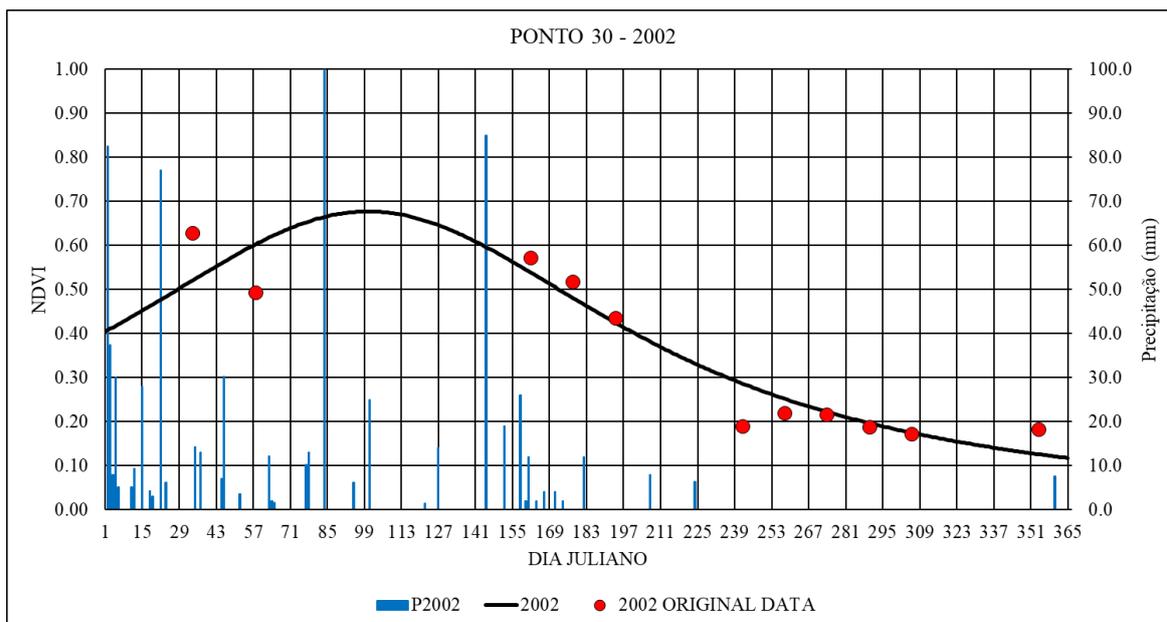




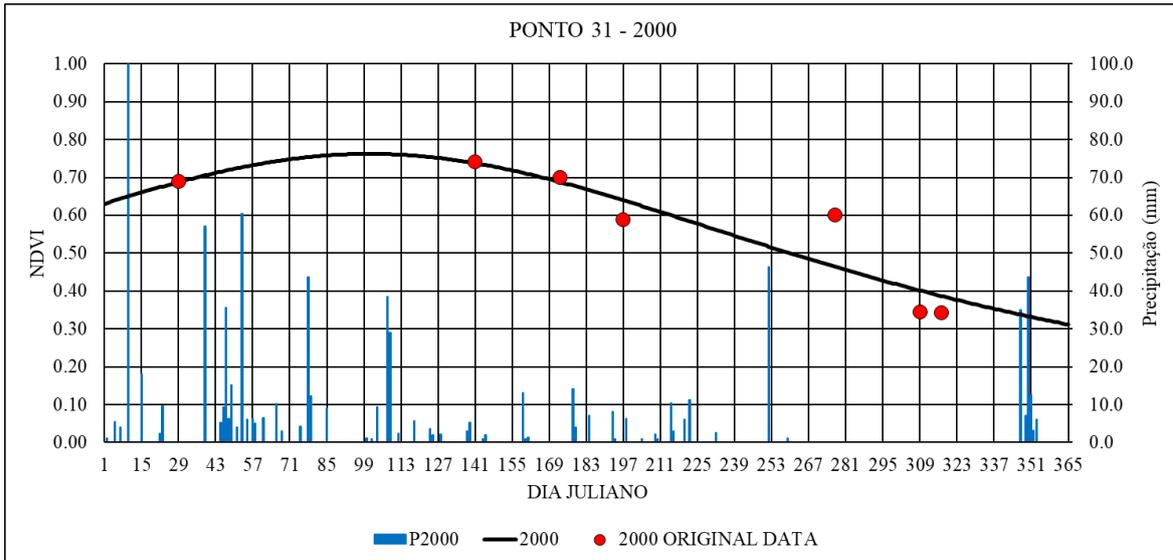
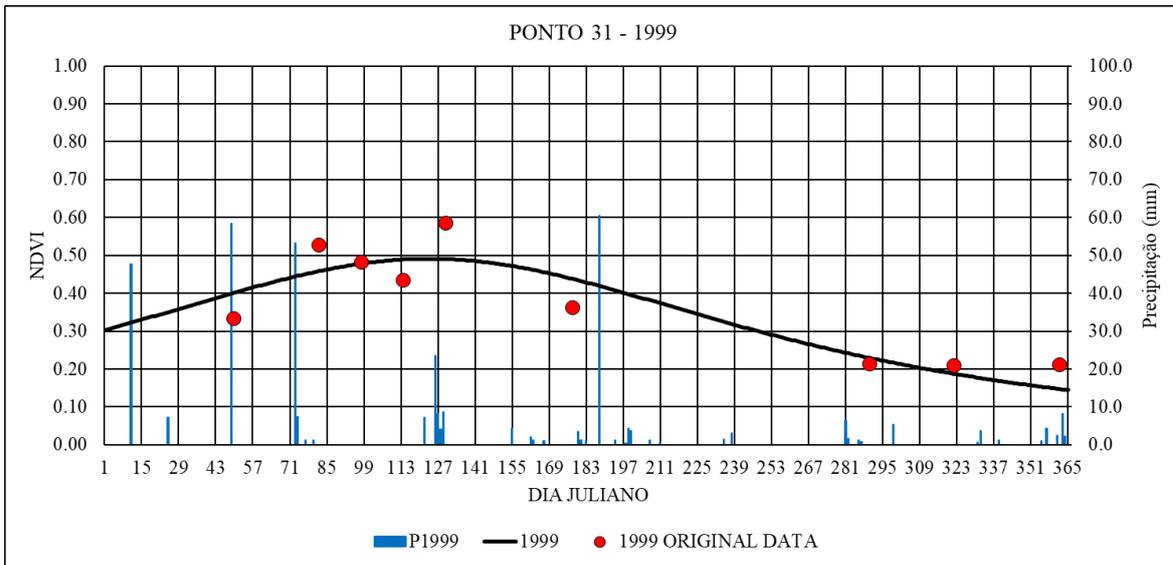
### PONTO 30

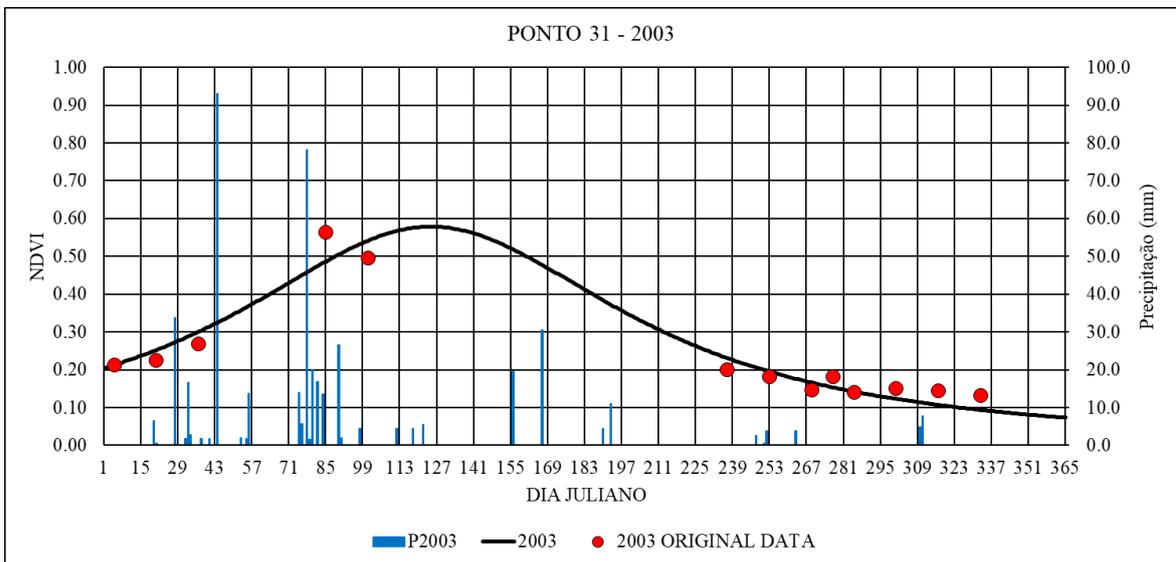
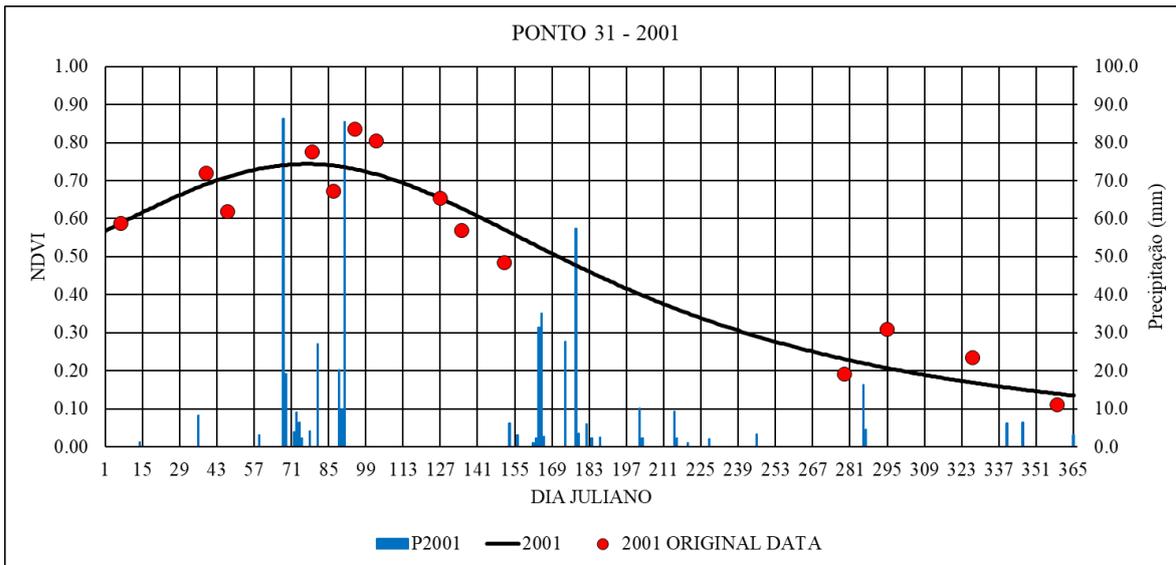


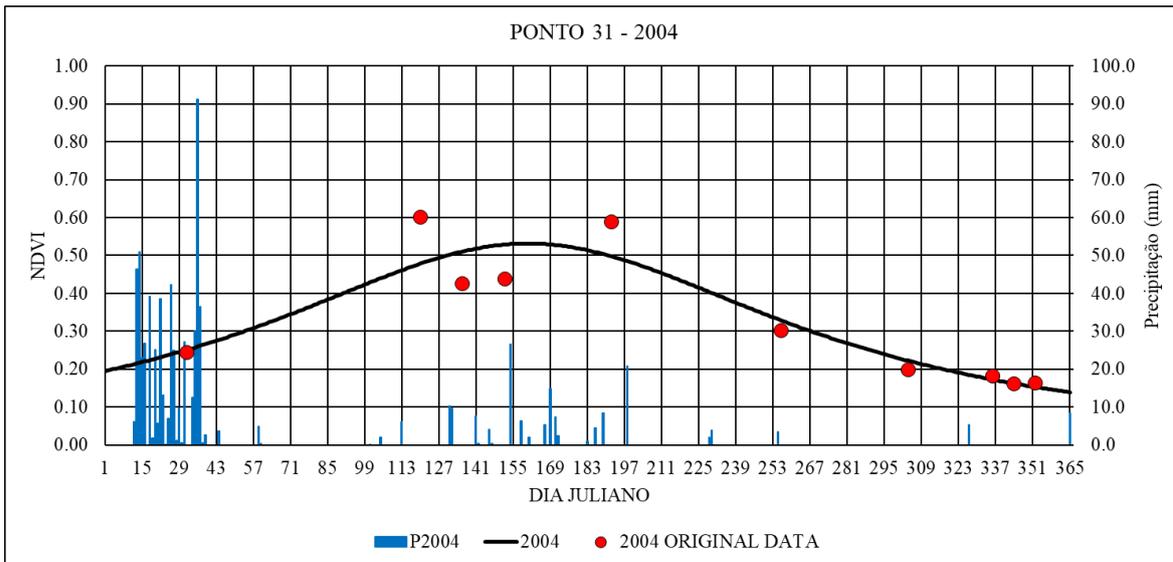




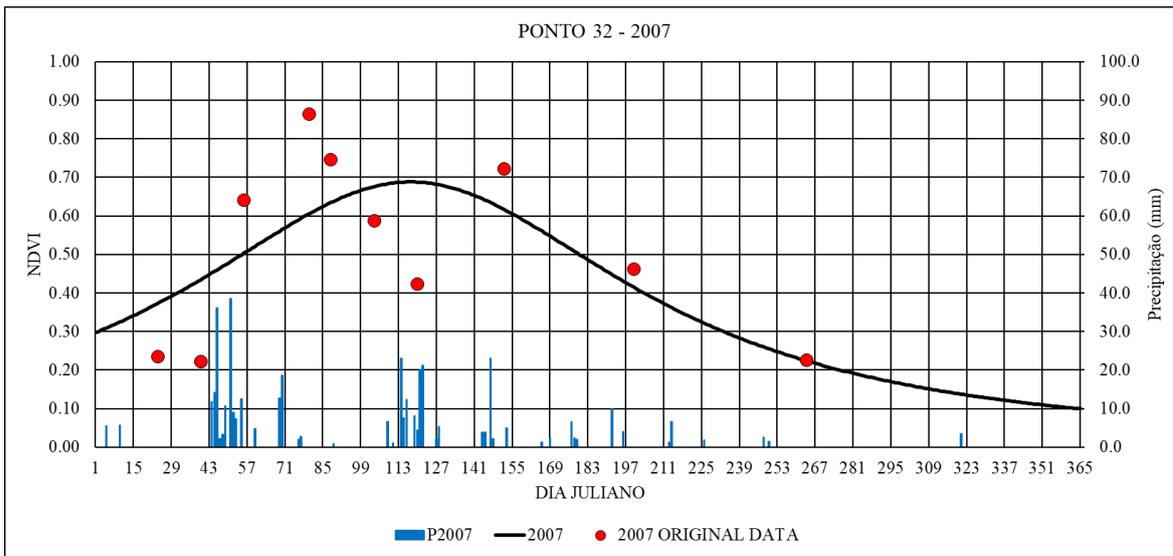
**PONTO 31**

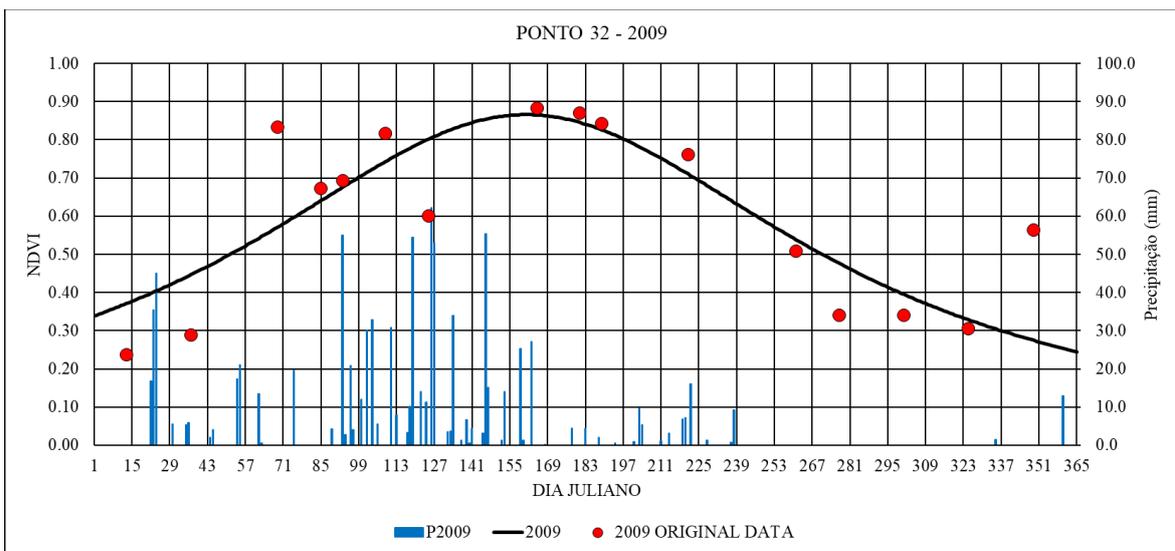
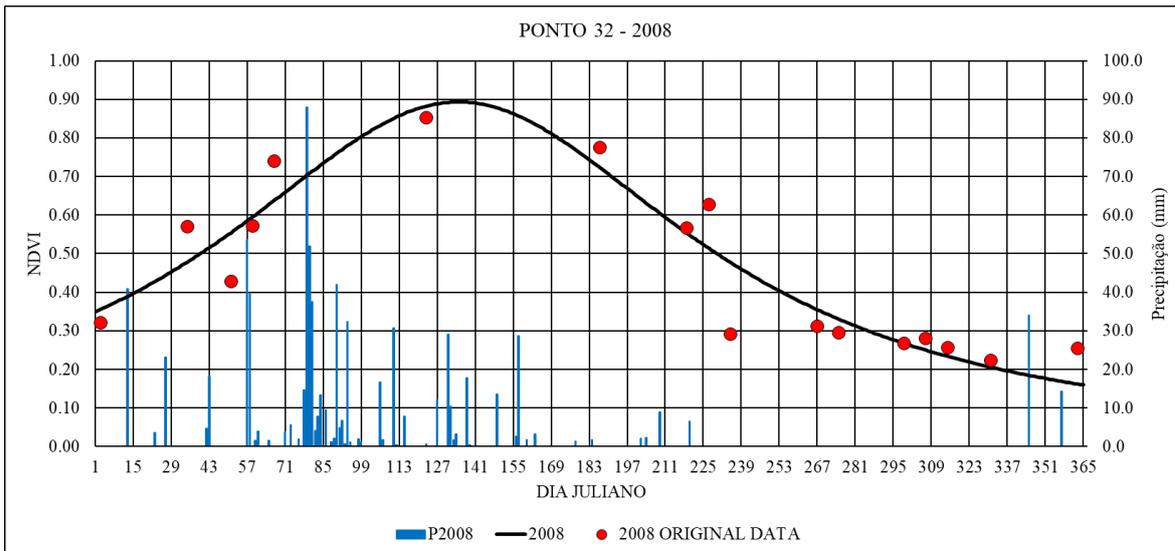


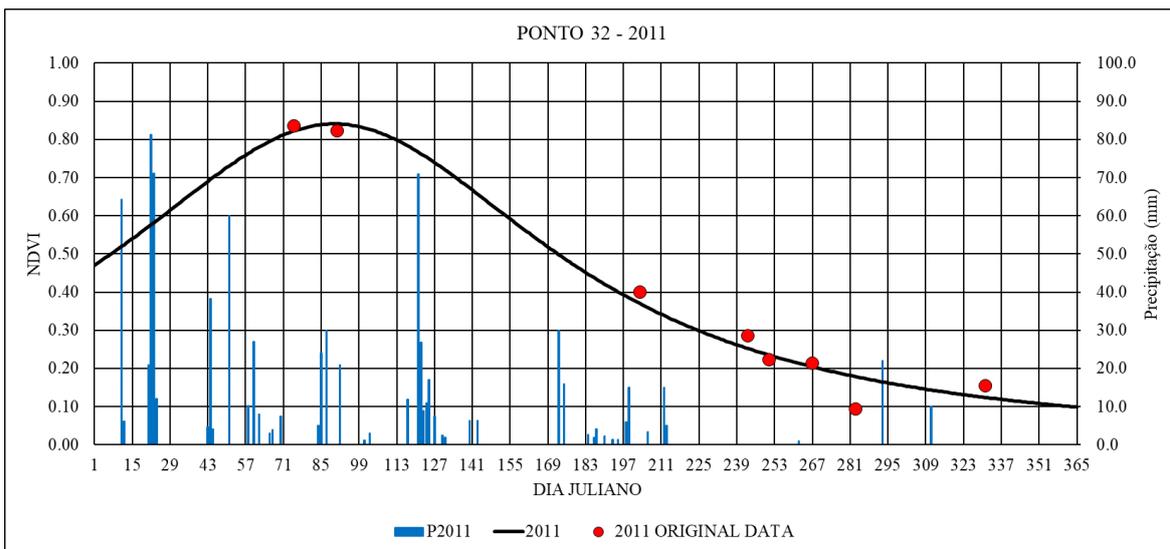
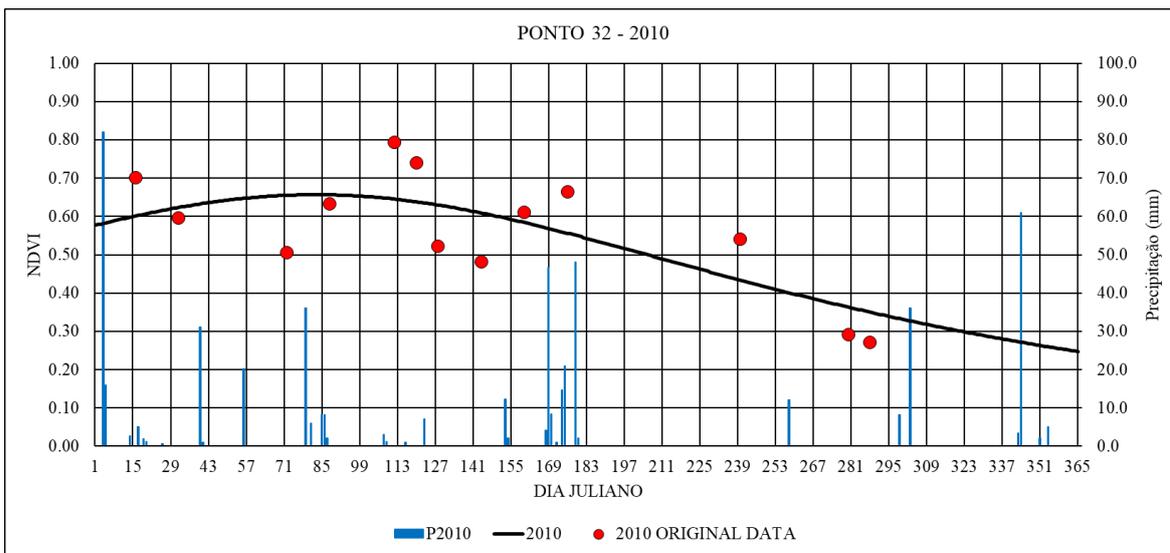


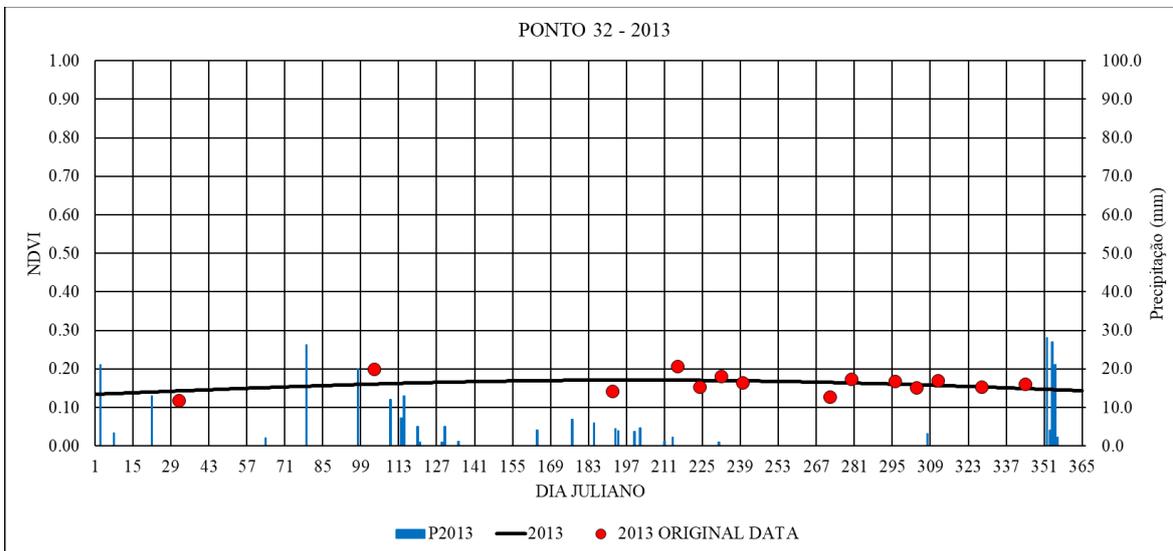
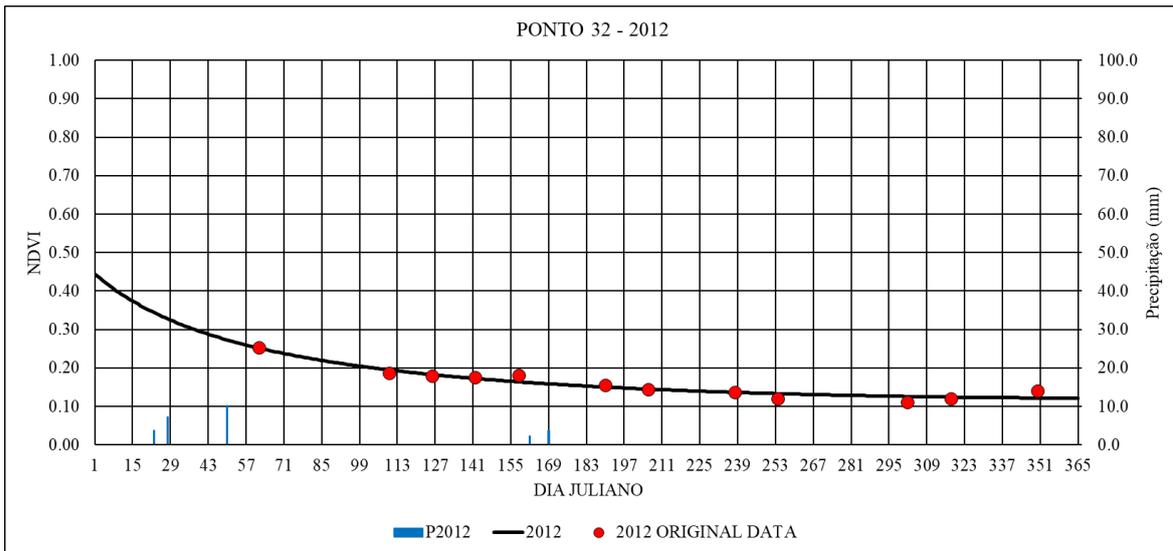


**PONTO 32**

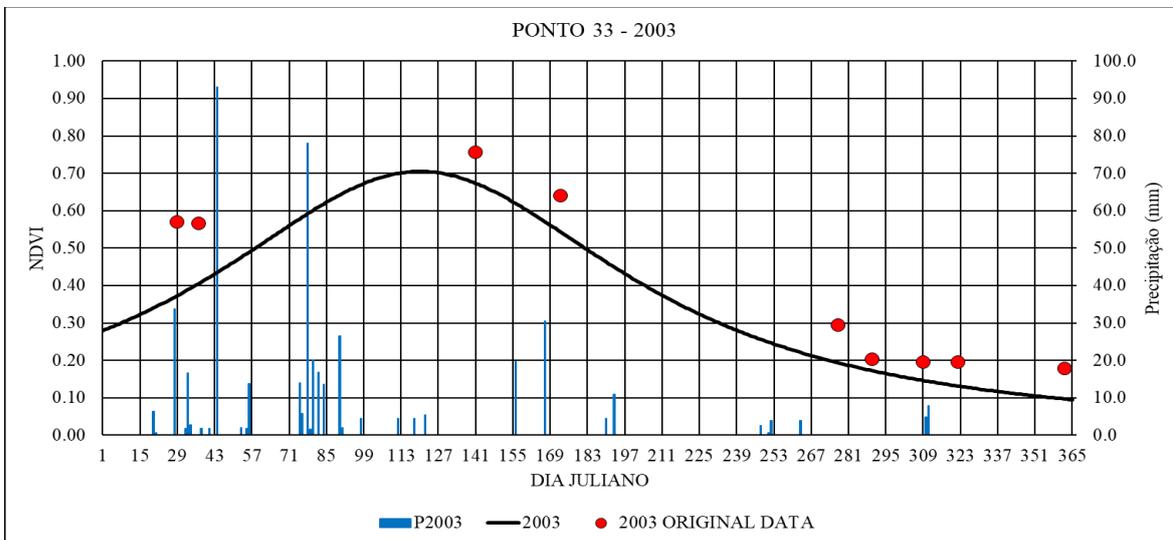


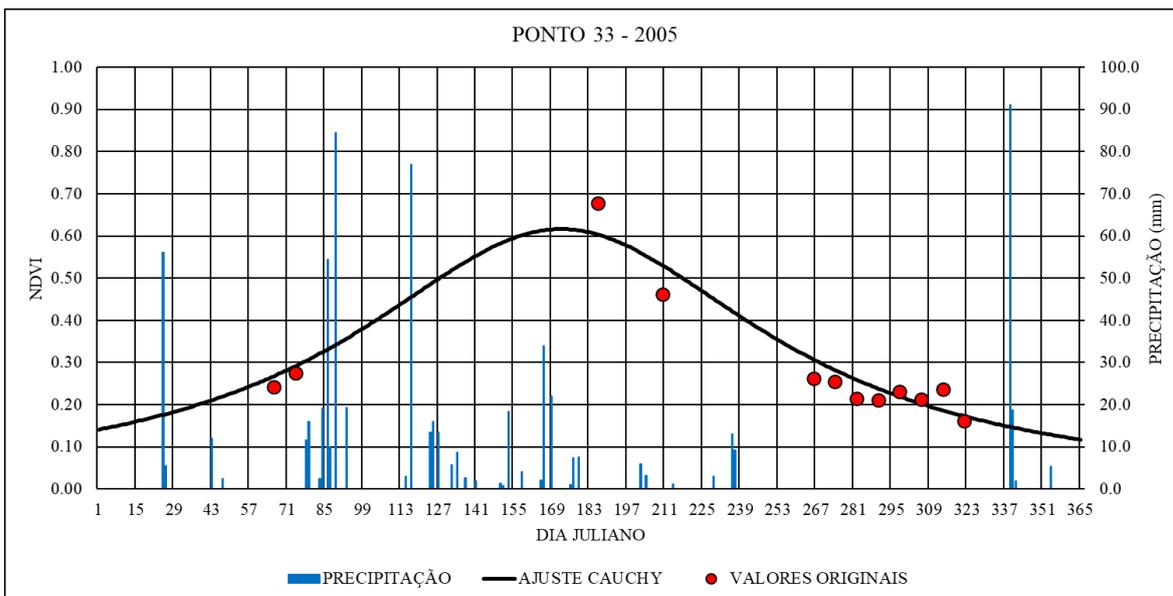
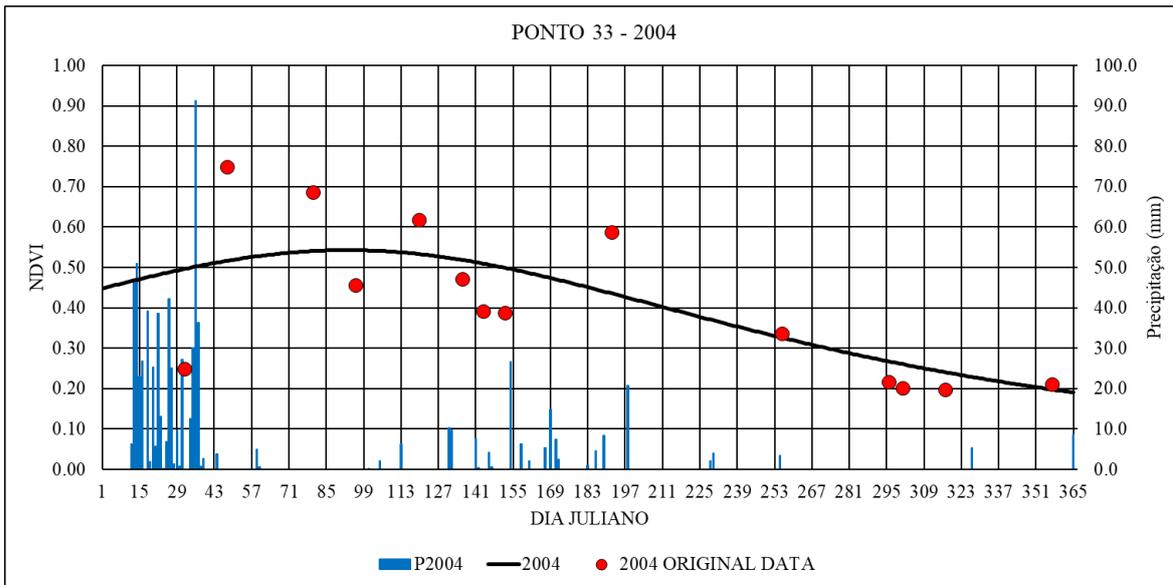


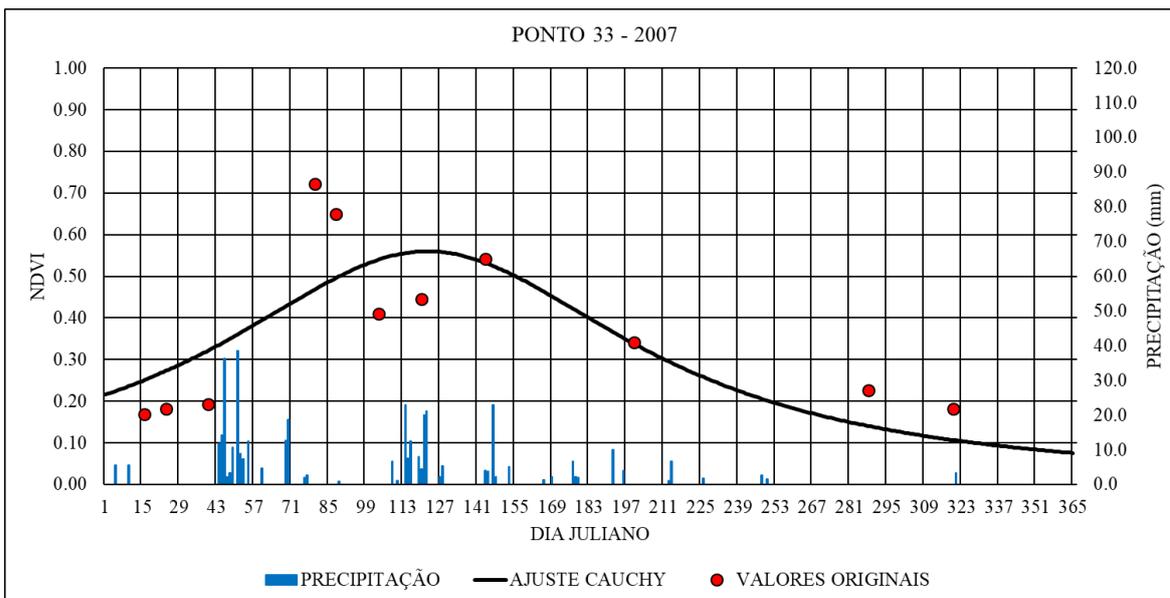
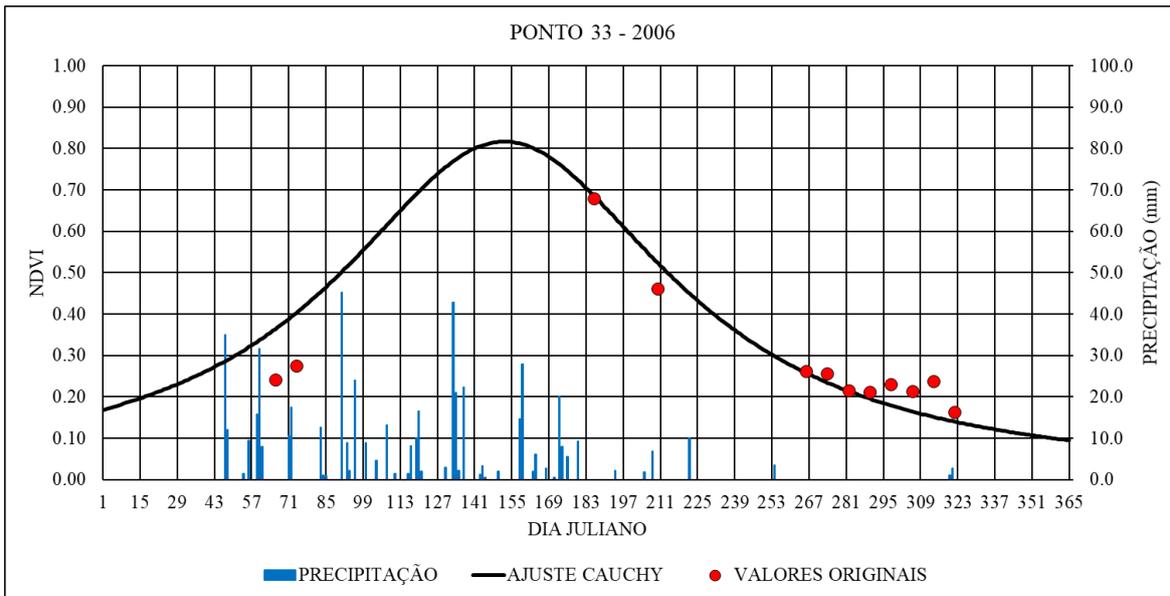


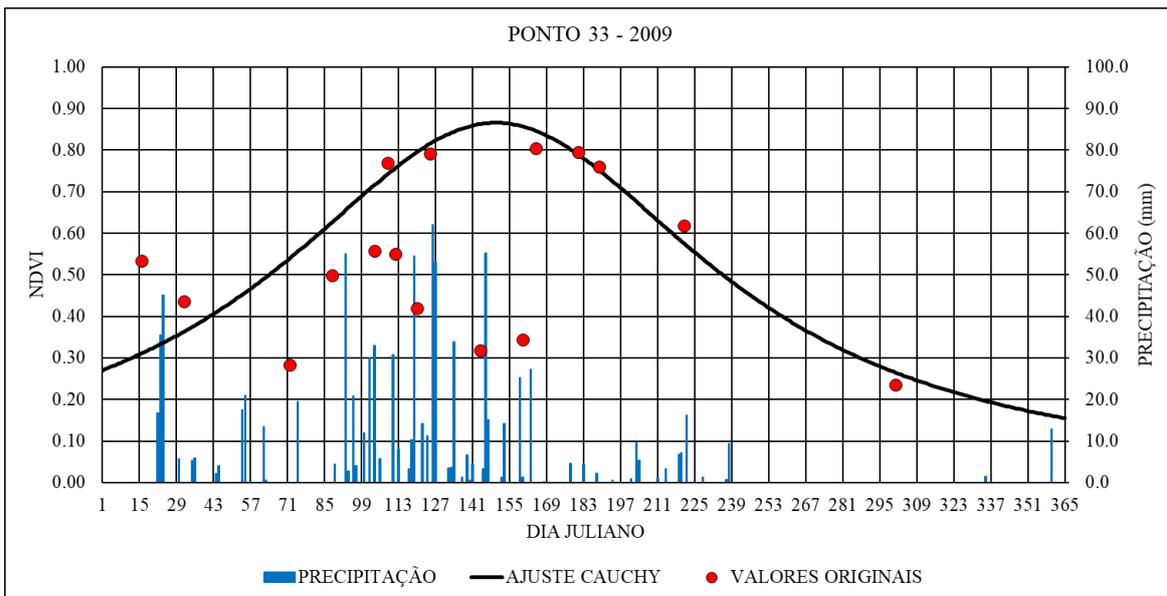
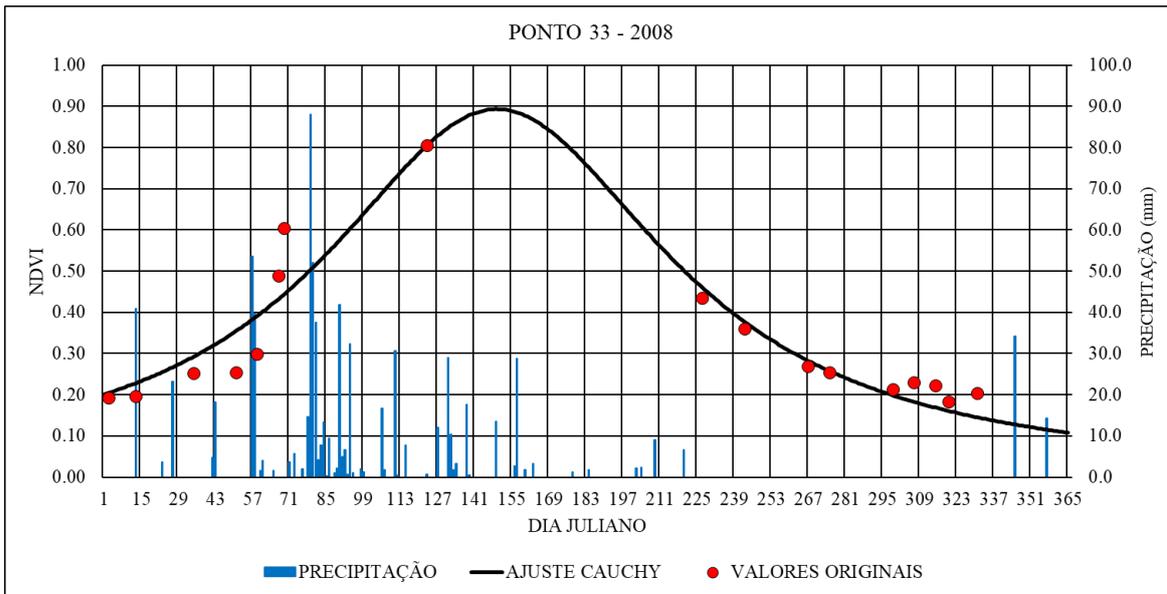


## PONTO 33









## ANEXO II – DADOS UTILIZADOS PARA VALIDAÇÃO DA FUNÇÃO CAUCHY

## PONTO 6 - 2002

DJ	SEM NUVEM	CAUCHY	SG	AG	DL
90	0,71	0,71	0,64	0,71	0,66
178	0,54	0,58	0,59	0,59	0,62
194	0,59	0,52	0,47	0,50	0,51
242	0,31	0,35	0,37	0,37	0,37
258	0,29	0,31	0,30	0,27	0,27
290	0,23	0,24	0,22	0,23	0,22
322	0,23	0,19	0,36	0,23	0,23
<b>RMSE</b>	-	0,0405	0,0807	0,0498	0,0553

## PONTO 6 - 2003

DJ	SEM NUVEM	CAUCHY	SG	AG	DL
5	0,35	0,35	0,32	0,36	0,30
69	0,40	0,44	0,45	0,45	0,45
101	0,51	0,46	0,46	0,46	0,47
237	0,35	0,36	0,38	0,36	0,37
253	0,35	0,34	0,31	0,30	0,31
285	0,24	0,29	0,25	0,27	0,26
333	0,23	0,23	0,25	0,26	0,24
357	0,27	0,21	0,27	0,27	0,27
<b>RMSE</b>	-	0,0355	0,0320	0,0326	0,0326

## PONTO 6 – 2004

DJ	SEM NUVEM	CAUCHY	SG	AG	DL
32	0,78	0,73	0,70	0,79	0,80
80	0,78	0,84	0,82	0,80	0,80
120	0,80	0,82	0,80	0,80	0,80
136	0,80	0,79	0,80	0,79	0,79
192	0,69	0,61	0,66	0,68	0,68
296	0,25	0,33	0,33	0,25	0,25
320	0,25	0,28	0,23	0,25	0,25
336	0,28	0,26	0,36	0,28	0,28
<b>RMSE</b>	-	0,0491	0,0527	0,0091	0,0087

**PONTO 6 – 2005**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
18	0,56	0,39	0,39	0,37	0,80
66	0,44	0,58	0,39	0,43	0,80
170	0,81	0,81	0,81	0,83	0,80
186	0,81	0,76	0,81	0,78	0,79
266	0,36	0,42	0,38	0,37	0,68
298	0,32	0,32	0,36	0,33	0,25
314	0,28	0,29	0,36	0,35	0,25
<b>RMSE</b>	-	0,0824	0,0692	0,0742	0,1900

**PONTO 6 – 2006**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
29	0,36	0,44	0,41	0,40	0,42
69	0,64	0,55	0,60	0,61	0,65
125	0,67	0,69	0,70	0,68	0,70
165	0,70	0,71	0,68	0,68	0,69
237	0,59	0,56	0,57	0,61	0,55
245	0,51	0,53	0,49	0,50	0,47
285	0,36	0,42	0,40	0,39	0,39
333	0,38	0,31	0,34	0,34	0,34
341	0,30	0,30	0,32	0,33	0,33
<b>RMSE</b>	-	0,0519	0,0324	0,0304	0,0357

**PONTO 33 – 2005**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
74	0,2747	0,27	0,33	-	-
210	0,4613	0,46	0,38	-	-
266	0,2615	0,27	0,32	-	-
282	0,2148	0,23	0,22	-	-
306	0,2127	0,18	0,19	-	-
322	0,1622	0,16	0,20	-	-
<b>RMSE</b>	-	0,0152	0,0494	-	-

**PONTO 33 – 2006**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
29	0,2161	0,22	0,18	0,19	0,21
69	0,3613	0,36	0,48	0,48	0,29
125	0,7290	0,73	0,63	0,67	0,74
213	0,4940	0,49	0,52	0,49	0,49
245	0,3201	0,32	0,34	0,32	0,31
277	0,2135	0,21	0,20	0,20	0,20
317	0,1374	0,14	0,14	0,14	0,15
341	0,1089	0,11	0,14	0,14	0,14
<b>RMSE</b>	-	0,000013	0,058694	0,051249	0,028144

**PONTO 33 – 2007**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
16	0,1696	0,23	0,22	0,20	0,21
40	0,1934	0,29	0,32	0,29	0,33
88	0,6487	0,45	0,46	0,46	0,44
104	0,4104	0,51	0,52	0,54	0,48
144	0,5424	0,55	0,49	0,54	0,49
200	0,3418	0,38	0,39	0,30	0,43
288	0,2271	0,16	0,21	0,18	0,18
320	0,182	0,12	0,19	0,17	0,17
<b>RMSE</b>	-	0,0931	0,0938	0,0914	0,0998

**PONTO 33 – 2008**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
3	0,1925	0,20	0,20	0,24	0,25
51	0,2541	0,34	0,29	0,26	0,31
67	0,4873	0,42	0,54	0,41	0,50
123	0,8043	0,80	0,76	0,84	0,81
227	0,4341	0,45	0,47	0,41	0,34
267	0,2677	0,28	0,30	0,26	0,26
299	0,2117	0,19	0,23	0,22	0,22
315	0,2223	0,16	0,18	0,21	0,21
<b>RMSE</b>	-	0,0457	0,0362	0,0361	0,0428

**PONTO 33 – 2009**

<b>DJ</b>	<b>SEM NUVEM</b>	<b>CAUCHY</b>	<b>SG</b>	<b>AG</b>	<b>DL</b>
13	0,1955	0,3021	0,30	0,21	0,20
69	0,6045	0,5251	0,53	0,64	0,50
109	0,7679	0,7438	0,74	0,75	0,71
125	0,7914	0,8168	0,82	0,79	0,79
165	0,8033	0,8453	0,84	0,79	0,80
189	0,7561	0,7486	0,75	0,75	0,78
221	0,6168	0,5723	0,57	0,63	0,68
301	0,234	0,2623	0,26	0,23	0,24
<b>RMSE</b>	-	0,0542	0,0542	0,0153	0,0510



