



**UNIVERSIDADE FEDERAL DO CEARÁ
INSTITUTO DE CIÊNCIAS DO MAR
GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS**

DIEGO XAVIER BEZERRA

**VARIABILIDADE ESPAÇO-TEMPORAL DO NDVI
GERADO A PARTIR DO SATÉLITE TERRA/MODIS
SOBRE O NORDESTE BRASILEIRO**

**FORTALEZA
2018**

DIEGO XAVIER BEZERRA

VARIABILIDADE ESPAÇO-TEMPORAL DO NDVI
GERADO A PARTIR DO SATÉLITE TERRA/MODIS
SOBRE O NORDESTE BRASILEIRO

Monografia apresentada ao Curso de Graduação em Ciências Ambientais do Instituto de Ciências do Mar (LABOMAR) da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Ciências Ambientais

Orientador: Prof Dr. Antônio Geraldo Ferreira

FORTALEZA
2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- X18v Xavier Bezerra, Diego.
Variabilidade espaço-temporal do NDVI gerado a partir do satélite TERRA/MODIS sobre o Nordeste Brasileiro / Diego Xavier Bezerra. – 2018.
77 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Instituto de Ciências do Mar, Curso de Ciências Ambientais, Fortaleza, 2018.
Orientação: Prof. Dr. Antônio Geraldo Ferreira.
1. Região Nordeste do Brasil. 2. Sensoriamento Remoto. 3. Sensor MODIS. 4. Satélite TERRA. 5. NDVI. I. Título.

CDD 333.7

DIEGO XAVIER BEZERRA

VARIABILIDADE ESPAÇO-TEMPORAL DO NDVI
GERADO A PARTIR DO SATÉLITE TERRA/MODIS
SOBRE O NORDESTE BRASILEIRO

Monografia apresentada ao Curso de Graduação em Ciências Ambientais do Instituto de Ciências do Mar (LABOMAR) da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Ciências Ambientais

Orientador: Prof Dr. Antônio Geraldo Ferreira

Aprovada em: ___/___/___.

BANCA EXAMINADORA

Prof. Dr. Antônio Geraldo Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Marcus Vinícius Chagas da Silva
Universidade Federal do Ceará (UFC)

Prof. Dr. Manuel Rodrigues de Freitas Filho
Fundação Cearense de Recursos Hídricos e Meteorologia (FUNCEME)

*Em memória do vô Assis
e da vô Carmelina*

AGRADECIMENTOS

Ao meu pai Argemiro, meu maior exemplo de dedicação, e à minha mãe Elina por todo amor o desse mundo.

Aos meus irmãos, Caio e Mariane, que cresceram junto comigo.

À minha namorada, Caroline, pela paciência, ajuda e companheirismo nos momentos mais difíceis.

Ao professor Geraldo Ferreira pelos conselhos, discussões, contribuições e amizade.

Ao Francisco das Chagas Junior e Robson Franklin, pela confiança e por me oferecer a oportunidade de aplicar este trabalho.

À Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) por disponibilizar os dados e por me oferecer o contato com profissionais de diversas áreas do conhecimento.

Aos meus colegas da Modelagem Numérica na FUNCEME pela imensa ajuda e esclarecimento de dúvidas, além das risadas do dia a dia.

Aos professores convidados da banca examinadora, Marcus Vinícius e Manuel Rodrigues, por aceitarem o convite e e pelas contribuições para o melhoramento deste trabalho.

À Universidade Federal do Ceará por proporcionar excelentes professores, nos quais estimularam minha busca pelo conhecimento e crescimento pessoal.

Aos meus colegas do curso de Ciências Ambientais.

RESUMO

No Nordeste Brasileiro (NEB) a questão da degradação de terras, das secas e da desertificação têm apresentado consequências nos âmbitos político, econômicos e sociais. Informações sobre a vegetação derivada de sensores remotos tem auxiliado no monitoramento e na identificação de tendências históricas e de áreas de degradação. Além de propor ferramentas para a aquisição e pré-processando de dados MODIS, o presente trabalho buscou a análise do comportamento da vegetação sobre o NEB por meio do índice de vegetação NDVI utilizando linguagem de programação *python* durante o período dos anos 2000 a 2017, sendo elencados os fatores de influência sobre a confiabilidade do dado e a variabilidade espaço-temporal deste índice. Através de análises de série temporal, medidas de estatística descritiva foram extraídas na busca da identificação de padrões e de tendências. Os resultados gerados mostram uma grande influência da precipitação sobre o NDVI, apresentando um crescimento vegetativo durante os anos de 2000 a 2011 sucedido por uma quebra abrupta no ano de 2012. Os padrões espaciais do NDVI mostram-se relacionados com a precipitação média na região, bem como as delimitações dos biomas Caatinga e Mata Atlântica, além dos enclaves úmidos existentes no semiárido. Se verificou que 16.3% dos dados de NDVI foram afetados pela presença de nuvens, ocasionando menor confiabilidade dos resultados em parte do Maranhão e na costa leste do NEB. Se recomenda a utilização das bandas de confiabilidade (*pixel reliability*) e qualidade (*VI quality*) em estudos de vegetação no NEB nas regiões mais problemáticas, como também a exploração de análises de correlação espacial e de técnicas de filtragem de dados defeituosos em trabalhos futuros.

Palavras-chave: Região Nordeste do Brasil. Sensoriamento Remoto. Sensor MODIS. Satélite TERRA. NDVI.

ABSTRACT

Land degradation, droughts and desertification on Brazilian Northeast Region (NEB) has been demonstrating consequences on the political, social and social spheres. Vegetation-based information derived from remote sensing has assisted the monitoring and history trend identification of degraded areas worldwide. In addition to tools for the acquisition and preprocessing of MODIS data, the present work perform an analysis on the NEB vegetation behaviour by using the NDVI and python programming language in the years 2000 to2017. Also, influencing factors concerning the NDVI reliability and its spatio-temporal patterns has been listed. Through time-series analysis, statistical measures were extracted aiming the identification of patterns and trends. The results shows vegetative grow during the years 2000-2011 with an consecutive abrupt negative trend on 2012 influenced by north Atlantic Ocean Sea Surface Temperature (SST). NDVI Spatial patterns shows similarity with mean precipitation and spatial delimitations of the biomes Caatinga and Mata Atlântica, as well as high altitude enclaves over the NEB semiarid portion. 16.3% of the NDVI data were found to be affected by the presence of clouds, spatially distributed on north of Maranhão state and NEB east coast. Specially on these regions it is recommended the utilisation of pixel reliability and quality bands. Future work might include investigation of defective data filtering techniques and spatial correlation analysis on NDVI and Precipitation data.

Keywords: Northeast Brazil. Remote Sensing. MODIS Sensor. TERRA Satellite. NDVI

LISTA DE FIGURAS E ILUSTRAÇÕES

| | |
|---|----|
| Figura 1 - Assinaturas espectrais da água limpa, vegetação sadia e solo seco..... | 17 |
| Figura 2 - Curvas espectrais para as folhas da espécie <i>Liquidambar styraciflua</i> em vários estágios de senescência..... | 19 |
| Figura 3 - Algoritmo da composição do produto MOD13Q1..... | 22 |
| Figura 4 - Precipitação média mensal para o NEB no período de 2000 a 2018..... | 24 |
| Figura 5 - Regimes de chuva do NEB..... | 25 |
| Figura 6 - Precipitação média mensal (mm) dos estados do NEB para o período 1998 a 2017..... | 25 |
| Figura 7 - Distribuição das temperaturas médias do ar para o NEB..... | 27 |
| Figura 8 - Localização da área de estudo..... | 28 |
| Figura 9 - Chapadas, planaltos e Serras sobre o NEB..... | 29 |
| Figura 10 - Delimitação dos Biomas do Brasil (IBGE)..... | 30 |
| Figura 11 - Etapas de aquisição e pré-processamento dos dados MODIS..... | 33 |
| Figura 12 - Obtenção das séries temporais dos <i>pixels</i> contaminados..... | 37 |
| Figura 13 - Obtenção das séries temporais do NDVI..... | 37 |
| Figura 14 - Distribuição espacial dos <i>pixels</i> falhos: (a) Dia do ano 49; (b) Dia do ano 209; (c) Médias anuais..... | 42 |
| Figura 15 - Curvas mínima, média, máxima e CV para o NDVI no NEB durante período 2000 a 2017..... | 43 |
| Figura 16 - Escore z do NDVI, média móvel do NDVI e Precipitação acumulada: (a) Anos 2000-2009; (b) Anos 2010-2017; (c) Ano de 2009; (d) Ano de 2012..... | 45 |
| Figura 17 - Distribuição espacial do NDVI médio e da Precipitação média considerando o período 2000 a 2017. (a) NDVI médio dos dias julianos 065-145; (d) Precipitação média dos dias julianos 065-145; (b) NDVI médio dos dias julianos 209-289; (e) Precipitação média dos dias julianos 209-289; (c) NDVI médio anual; (f) Precipitação média anual..... | 48 |
| Figura 18 - Distribuição espacial do CV no período 2000 a 2017: (a) dias julianos 065-145; (b) dias julianos 209-289; (c) Médias anuais..... | 50 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Especificações do produto MOD13Q1..... | 20 |
| Tabela 2 - Descrição da imagem de confiabilidade (pixel reliability) do produto MOD13Q1..... | 31 |
| Tabela 3 - Período e quantidade de imagens referente ao dia do ano das imagens MODIS.. | 32 |
| Tabela 4 - Tempo Computacional para produtos MODIS selecionados com escolha de formato final GeoTIFF e NetCDF..... | 40 |
| Tabela 5 - Porcentagem de pixels contaminados nas imagens de NDVI analisadas..... | 41 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|---------|---|
| 3D | Tridimensional |
| AF | Clima tropical úmido |
| Am | Clima de monção |
| ANA | Agência Nacional das Águas |
| As | Clima tropical com estação seca no verão |
| AVHRR | <i>Advanced Very High Resolution Radiometer</i> |
| Aw | Clima tropical com estação seca no inverno |
| BSh | Clima das estepes quentes de baixa latitude e altitude |
| CCM | Complexos Convectivos de Mesoescala |
| CPTEC | Centro de Previsão de Tempo e Estudos Climáticos |
| CV | Coefficiente de Variação |
| CV-MVC | <i>Constrained View Angle – Maximum Value Composite</i> |
| EMBRAPA | Empresa Brasileira de Pesquisa Agropecuária |
| ENOS | El Niño-Oscilação Sul |
| EVI | <i>Enhanced Vegetation Index</i> |
| FTP | <i>File Transfer Protocol</i> |
| FUNCEME | Fundação Cearense de Meteorologia e Recursos Hídricos |
| GDAL | <i>Geospatial Data Abstraction Library</i> |
| GeoTIFF | <i>Georeferenced Tagged Image File Format</i> |
| GTS | <i>Global Telecommunication System</i> |
| HDF | <i>Hierarchical Data Format</i> |
| IBGE | Instituto Brasileiro de Geografia e Estatística |
| INPE | Instituto Nacional de Pesquisas Espaciais |
| IVP | Espectro do Infra-Vermelho Próximo |
| LI | Linhas de Instabilidade |
| LST | <i>Land Surface Temperature</i> |
| LP-DAAC | <i>Land Process Distributed Active Archive Center</i> |
| MODIS | <i>Moderate Resolution Imaging Spectroradiometer</i> |

| | |
|-------------|--|
| MVC | <i>Maximum Value Composite</i> |
| NASA | <i>National Aeronautics and Space Administration</i> |
| OMJ | Ondas de Madden e Julian |
| PNM | Pressão ao Nível do Mar |
| RADAMBRASIL | Projeto Radar da Amazônia |
| SIRGAS | Sistema de Referência Geocêntrico para as Américas |
| SR | Sensoriamento Remoto |
| SRC | Sistema de Referência de Coordenadas |
| TSM | Temperatura da Superfície do Mar |
| VCAN | Vórtices Ciclônicos de Altos Níveis |
| VIS | Espectro do Visível |
| ZCAS | Zona de Convergência do Atlântico Sul |
| ZCIT | Zona de Convergência Intertropical |

SUMÁRIO

| | | |
|----------------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 2 | OBJETIVOS | 16 |
| 3 | REFERENCAL TEÓRICO | 17 |
| 3.1 | Sensoriamento remoto no estudo da vegetação | 17 |
| 3.2 | Índice de Vegetação por Diferença Normalizada (NDVI) | 18 |
| 3.3 | Sensor Moderate Imaging Spectroradiometer - MODIS | 20 |
| 3.4 | Algoritmo de composição das imagens MODIS | 21 |
| 3.5 | Aspectos climáticos do Nordeste Brasileiro | 22 |
| 3.5.1 | <i>Variabilidade Inter-anual da precipitação</i> | 23 |
| 3.5.2 | <i>Variabilidade Intra-anual da precipitação</i> | 24 |
| 3.5.3 | <i>Temperatura</i> | 26 |
| 4 | ÁREA DE ESTUDO E METODOLOGIA | 27 |
| 4.1 | Área de Estudo | 27 |
| 4.2 | Rotinas computacionais de aquisição e pré-processamento dos dados | 30 |
| 4.2.1 | <i>Download dos dados</i> | 31 |
| 4.2.2 | <i>Pré-processamento</i> | 33 |
| 4.3 | Dados de precipitação | 34 |
| 4.4 | Filtragem | 35 |
| 4.5 | Análise de confiabilidade | 36 |
| 4.6 | Análise espaço-temporal do NDVI | 36 |
| 5 | RESULTADOS E DISCUSSÕES | 39 |
| 5.1 | Desempenho das rotinas | 39 |
| 5.2 | Confiabilidade do NDVI | 40 |
| 5.3 | Análise espaço-temporal do NDVI | 43 |
| 5.3.1 | <i>Variabilidade temporal</i> | 43 |
| 5.3.1.1 | <i>Variabilidade intra-anual</i> | 43 |
| 5.3.1.2 | <i>Variabilidade interanual</i> | 44 |

| | | |
|---------|---|----|
| 5.3.2 | <i>Padrões espaciais</i> | 46 |
| 5.3.2.1 | <i>Distribuição espacial do NDVI</i> | 46 |
| 5.3.2.2 | <i>Distribuição espacial do coeficiente de variação</i> | 49 |
| 6 | CONCLUSÕES | 51 |

REFERÊNCIAS

APÊNDICE A - ROTINA DE AQUISIÇÃO DOS DADOS MODIS

APÊNDICE B - ROTINA DE PRÉ-PROCESSAMENTO

APÊNDICE C - FIGURAS DOS PIXELS FALHOS

APÊNDICE D - FIGURAS DO NDVI MÉDIO

1. INTRODUÇÃO

Ao longo do último século a humanidade tem modificado fortemente o meio natural através do seu modo de vida. Os efeitos dos impactos ocasionados nos solos, na água, na atmosfera e na biodiversidade despertam discussões globais sobre a necessidade de garantir um desenvolvimento econômico sustentável, no sentido que a sociedade continue sendo abastecida de serviços e que as suas fontes naturais sejam utilizadas de forma racional, assegurando o seu proveito para as gerações presentes e futuras. Sobretudo diante dos cenários de mudanças climáticas, essa tarefa torna-se ainda mais desafiadora.

No Nordeste do Brasil (NEB), que contém o semiárido mais populoso do mundo, a degradação de terras e a desertificação estão entre os mais graves problemas ambientais da atualidade, com consequências no âmbito político, econômico e social. A partir da Conferência das Nações Unidas sobre a Desertificação em 1977, ocorre um crescente interesse da ciência no entendimento dos fatores climáticos e antropogênicos sobre a variabilidade da vegetação em regiões áridas e semiáridas (FENSHOLT *et al.*, 2015).

Como ferramenta de observação da Terra, o Sensoriamento Remoto (SR) tem proporcionado valiosas informações no campo das ciências da natureza ao longo das últimas décadas, permitindo diagnósticos e monitoramento de sistemas físicos, químicos e biológicos terrestres em dimensões espaciais globais a locais. Na escala do tempo, o SR auxilia no entendimento de fenômenos do passado, do presente e possibilita a projeção de cenários futuros de degradação de terras (DOURADO, 2017).

Em estudos de vegetação, o Índice de Vegetação por Diferença Normalizada (NDVI) tem sido usados com considerável sucesso no monitoramento de secas (PETERS *et al.*, 2002; LEIVAS *et al.*, 2014), na identificação de áreas em processo de desertificação (ANDRADE *et al.*, 2007) e em estudos das conexões entre vegetação e clima no NEB (BARBOSA, 1999; LIU & JUÁREZ, 2001; BARBOSA *et al.*, 2006; ERASMI *et al.*, 2009; SCHUCKNECHT *et al.*, 2013). Com um olhar sobre estes estudos, se verifica que a partir do uso das séries temporais do NDVI é possível identificar o comportamento da vegetação ao longo do tempo e, conjuntamente com dados meteorológicos, os fatores de influência da sua variabilidade podem ser investigados a fundo.

Não obstante, observando o grande volume de dados utilizados nessas investigações, a aquisição, o processamento e a extração de informação tornam-se uma tarefa onerosa quando realizada de forma manual por meio de *softwares* de análise geoespacial tradicionais, sobretudo quando se considera as crescentes fontes fontes de informação geográfica e lançamentos de novos sensores remotos. Nesse sentido a linguagem de programação *python* tem se mostrado poderosa em análises de geoprocessamento, possuindo a vantagem de facilitar a automatização de tarefas específicas e repetitivas, além permitir a construção e o fácil compartilhamento de ferramentas geoespaciais (LAWHEAD, 2015; RÉGO, 2017).

Diante disso, se observa um potencial auxílio à gestão dos recursos naturais através do subsídio de dados por meio de rotinas operacionais com programação, especialmente por meio do monitoramento ambiental sistemático da vegetação. Considerando estas possibilidades, segue os objetivos deste trabalho.

2. OBJETIVOS

O objetivo principal é analisar o comportamento do NDVI no NEB tanto ao longo dos anos (variabilidade interanual) como também dentro dos anos (variabilidade intra-anual).

Paralelamente, buscou-se os seguintes objetivos específicos:

- Desenvolver rotinas computacionais para a obtenção e pré-processamento automático dos dados dos produtos MODIS para a obtenção final de uma base de dados para o NEB;
- Investigar a confiabilidade dos dados NDVI no NEB pela verificação da presença de nuvens nos *pixels* do produto MOD13Q1;
- Identificar padrões espaço-temporais do NDVI no NEB e comparar com dados de precipitação, com as delimitações dos biomas e com o relevo.

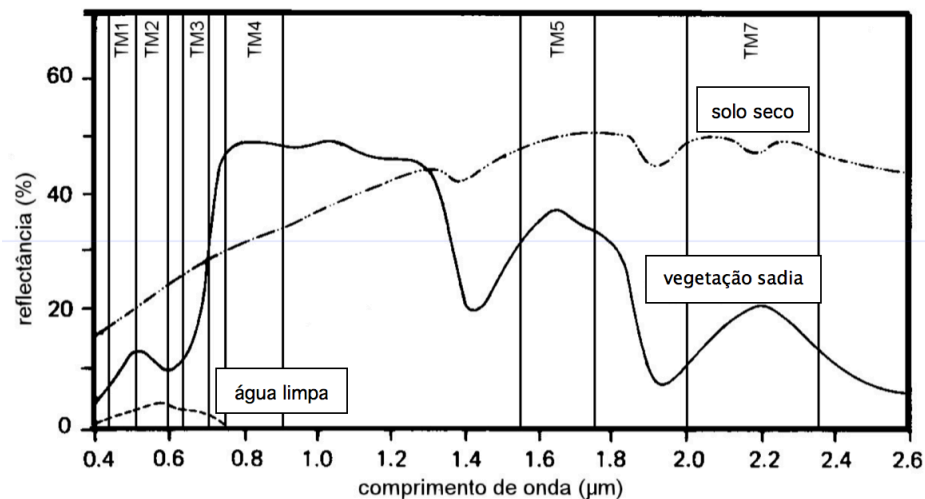
3. REFERENCIAL TEÓRICO

3.1 Sensoriamento remoto no estudo da vegetação

Sensoriamento Remoto (SR) é definido por Lorenzetti (2015, p.16) como “a aquisição de informação sobre alguma propriedade de um objeto ou fenômeno sem contato físico com ele”. No contexto da observação da superfície terrestre por sensores orbitais, as técnicas de SR são fundamentadas pelos processos de interação entre a radiação eletromagnética e os diferentes recursos naturais como a água, as rochas, os solos e a vegetação (PONZONI & SHIMABUKURO, 2010).

Para alvos distintos, é possível distingui-los através de assinaturas espectrais, obtidas pela relação entre a intensidade que cada alvo reflete a radiação eletromagnética em cada comprimento de onda (JENSEN *et al.*, 2005). Na Figura 1 se observa assinaturas espectrais distintas entre água limpa, solo seco e vegetação sadia. De acordo com

Figura 1 - Assinaturas espectrais da água limpa, vegetação sadia e solo seco.



Fonte: Adaptado de Lillesand & Kiefer (1987).

O SR possui a vantagem de coletar dados sistemáticos a partir da observação de amplas áreas da superfície terrestre, na medida que coletas em dados pontuais podem ser dispendiosas e causar distúrbios no objeto ou na área de interesse (JENSEN, 2009).

Acoplados à plataformas orbitais, diversos sensores são utilizados em estudos de vegetação, a exemplo: *Operational Land Imager* no Landsat 8, *Thematic Mapper* no Landsat 5, AVHRR no NOAA, *Vegetation* no SPOT e *Moderate Resolution Imaging Spectroradiometer* (MODIS) na plataforma TERRA.

No Brasil, técnicas de SR nos estudos de vegetação são empregadas desde a década de 40, destacando-se:

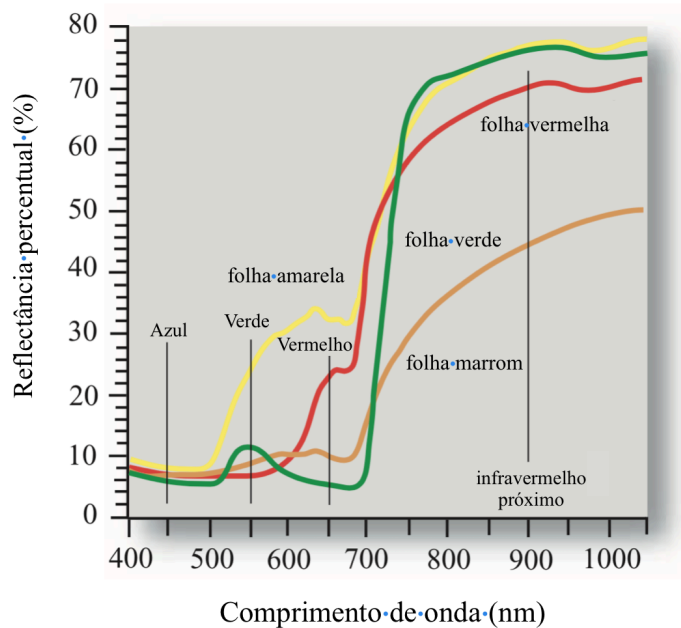
[...] um dos marcos mais significativos dessa aplicação tenha sido o Projeto RADAMBRASIL, que teve como objetivo não só representar espacialmente classes fisionômicas da cobertura vegetal de todo o território nacional, como também os demais itens fundamentais de estudos sobre o meio ambiente e dos recursos naturais como geologia, geomorfologia e solos. O trabalho foi realizado a partir de imagens de um radar aerotransportado e tem servido como referência para inúmeras iniciativas de mapeamento em todo o país até hoje. (PONZONI & SHIMABUKURO, 2010, p.2-3).

3.2 Índice de Vegetação por Diferença Normalizada (NDVI)

Como foi observado na Figura 1, a vegetação sadia possui baixa reflectância no espectro do visível (VIS) e alta no infra-vermelho próximo (IVP). Sendo as folhas o principal órgão fotossintetizante das plantas, a ausência de pigmentação da clorofila e de carotenos tende a causar maior reflectância no VIS, sobretudo nas faixas 535-640 e 685-700 nm, enquanto a resposta no IVP acontece somente em estados crítico de desidratação da folha (Figura 2) (ver JENSEN, 2009, p. 363-366).

Com base na relação das reflectâncias do VIS e do IVP, uma gama de índices de vegetação foram propostos com o propósito de estimar mudanças na cobertura vegetal, como a exemplo do *Vegetation Health Index* (VHI), *Enhanced Vegetation Index* (EVI) e o *Soil Adjusted Vegetation Index* (SAVI) (LYON *et al.*, 1998). Entre mais de 150 índices de vegetação existentes, o NDVI se destaca como o índice mais utilizado (NOVAS *et al.*, 2008; YENGOH *et al.*, 2015, p.12).

Figura 2 - Curvas espectrais para as folhas da espécie *Liquidambar styraciflua* em vários estágios de senescência.



Fonte: Adaptado de Jensen (2009).

O NDVI é calculado pela razão das diferenças entre as bandas do IVP e do vermelho (V) com a soma do IVP e do V, através da Equação 1 (ROUSE *et al.*, 1974), variando de -1 a +1. A razão entre as bandas contribui para a redução de ruídos provenientes de nuvens, sombras, ângulo solar, topografia e efeitos de atenuação atmosférica (ANDERSON *et al.*, 2005; JENSEN, 2009).

$$NDVI = \frac{(IVP - V)}{(IVP + V)} \quad (1)$$

onde IVP é a reflectância na banda do infra-vermelho próximo e V é a reflectância na banda vermelha do espectro visível.

O NDVI tem sido utilizado com êxito no monitoramento das mudanças na vegetação em diversas escalas por meio da construção de perfis sazonais e temporais, auxiliando na detecção dos períodos de crescimento, pico verde, mudanças fisiológicas das folhas e períodos de senescência (RODRIGUES, 2010). Ademais, o NDVI pode ser

empregado em estudos de desertificação, erosão do solo, queimadas, fluxo de carbono, monitoramento de ecossistemas e de secas (YENGOH *et al.*, 2015).

3.3 Sensor Moderate Imaging Spectroradiometer - MODIS

O sensor MODIS é um dos cinco instrumentos do satélite TERRA, projetado para atender estudos do continente e da atmosfera. Ribeiro *et al.* (2007) destaca que o MODIS tem a vantagem de possuir alta sensibilidade radiométrica (12 *bits*), alta resolução espectral (36 bandas na faixa 0,4 - 14,4 μ m), além de possuir resolução temporal diária.

A classe dos produtos terrestres MODIS voltada à estimação de temperatura do continente (*Land Surface Temperature - LST*), evapotranspiração, reflectância e à índices de vegetação. As resoluções espaciais dos produtos dos índices de vegetação (MOD13) variam de 250m à 5600m, com resoluções temporais diárias, de 16 dias e mensais. Diante da diversidade de produtos, Lopes (2014) afirma que pesquisadores devem escolher com cuidado qual produto utilizar, podendo chegar a diferentes resultados de acordo com cada tipo de dado. As bandas presentes no produto MOD13Q1 são apresentadas na Tabela 1.

Tabela 1 - Especificações do produto MOD13Q1.

| Conjunto de Dados (camadas HDF) | Unidade | Faixa Válida | Fator de escala |
|---|--------------------|--------------|-----------------|
| 250m 16 days NDVI | NDVI | -2000, 10000 | 0.0001 |
| 250m 16 days EVI | EVI | -2000, 10000 | 0.0001 |
| 250m 16 days VI Quality detailed QA | Bits | 0, 65534 | - |
| 250m 16 days red reflectance (Band 1) | Reflectância | 0, 10000 | 0.0001 |
| 250m 16 days NIR reflectance (Band 2) | Reflectância | 0, 10000 | 0.0001 |
| 250m 16 days blue reflectance (Band 3) | Reflectância | 0, 10000 | 0.0001 |
| 250m 16 days MIR reflectance (Band 7) | Reflectância | 0, 10000 | 0.0001 |
| 250m 16days view zenith angle | Graus | -9000, 9000 | 0.01 |
| 250m 16 days sun zenith angle | Graus | -9000, 9000 | 0.01 |
| 250m 16 days relative azimuth angle | Graus | -3600, 3600 | 0.1 |
| 250m 16 days composite day of the year | Dia juliano do ano | 1, 366 | - |
| 250m 16 days pixel reliability summary QA | Rank | 0, 3 | - |

Fonte: Adaptado de Didan *et al.* (2005).

3.4 Algoritmo de composição das imagens MODIS

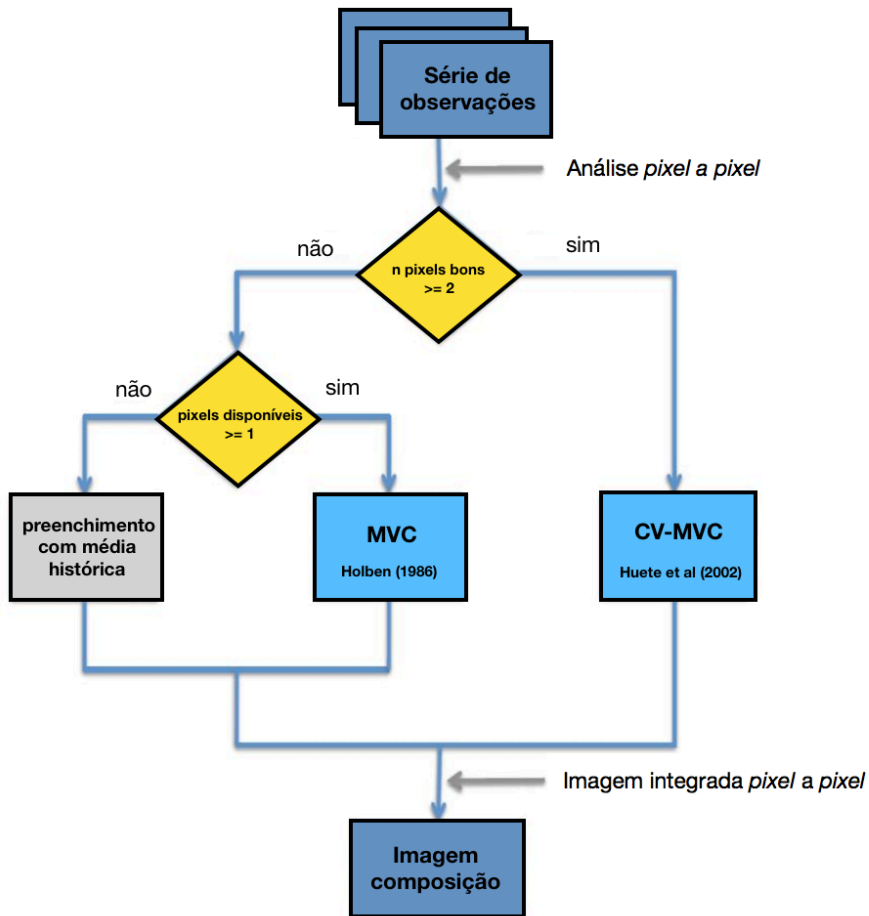
Por conta da sobreposições de órbitas e múltiplas observações diárias nos produtos MOD13, um máximo de 64 observações podem ser coletadas em um período de 16 dias. Com isso, nas imagens observadas é utilizado um algoritmo de composição que realiza operações *pixel a pixel*, selecionando para cada dia a melhor observação possível (Figura 3). O algoritmo utiliza as bandas de qualidade do *pixel (VI quality)*, que indicam a presença de água, nuvens, sombras e aerossóis.

Uma das técnicas empregadas pelo algoritmo consiste do *Maximum Value Composite (MVC)*, proposta por Holben (1986), na qual seleciona as observações baseando-se nos valores máximos de NDVI; assim minimizando efeitos de contaminação de nuvem e de aerossóis. Embora a qualidade do NDVI seja otimizada com esse método, *pixels* de maior ângulo de visada ainda são selecionados, introduzindo distorções geométricas nas imagens.

Auxiliando na atenuação destes problemas, Huete *et al.* (2002) apresentou a técnica *Constrained View Angle - Maximum Value Composite (CV-MVC)* partindo de critérios de integridade do dado e de ângulos de visada próximos ao nadir¹. No algoritmo dos produtos MOD13, essas duas técnicas são utilizadas dependendo da quantidade de observações consideradas boas (DIDAN *et al.*, 2015). Se a quantidade observações boas for igual a 0, a média histórica do NDVI do *pixel* é utilizada como preenchimento.

¹ o termo nadir é utilizado para definir a perpendicular à superfície terrestre a partir do satélite.

Figura 3 - Algoritmo da composição do produto MOD13Q1.



Fonte: Adaptado de Didan *et al.* (2005).

3.5 Aspectos climáticos do Nordeste Brasileiro

Os tipos climáticos no NEB são classificados por Alvares *et al.* (2013), utilizando os critérios de Köppen, como Tropical (Aw, As e AF), Semiárido (BSh) e Equatorial Úmido (Am). O clima semiárido, predominante no NEB, é marcado por um balanço hídrico anual negativo, apresentando elevadas taxas de evapotranspiração durante o ano, com excedente hídrico apenas em fevereiro a maio (MARENGO *et al.*, 2011; NOBRE, 2012).

No NEB ocorre uma alta variabilidade interanual da precipitação, com algumas ocorrências de anos excepcionalmente secos e anos excepcionalmente chuvosos, como também uma alta variabilidade intra-anual da precipitação, constituída por um regime de

chuvas concentrado em uma parte do ano. Essas variações na precipitação podem ser influenciadas de forma isolada ou conjunta por diversos sistemas meteorológicos (FEITOSA, 2016).

Uvo & Berndtsson (1996) apontam os principais mecanismos atuantes na precipitação da região, sendo eles: (1) Eventos El Niño-Oscilação Sul (ENOS); (2) Temperatura da superfície do mar (TSM) no oceano Atlântico, Ventos Alísios, Pressão ao Nível do Mar (PNM); (3) Zona de Convergência Intertropical (ZCIT); (4) Frentes Frias, e (5) Vórtices Ciclônicos de Altos Níveis (VCAN). Não obstante, ressaltam-se outros mecanismos como a Zona de Convergência do Atlântico Sul (ZCAS), as Ondas de Leste, as Ondas Madden e Julian e as Brisas Marítimas e Terrestres.

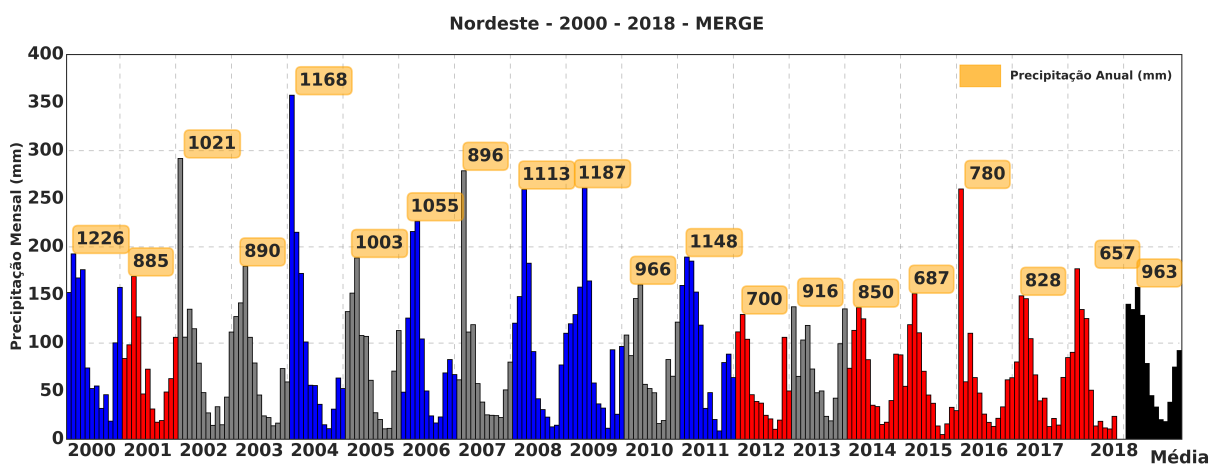
3.5.1 Variabilidade Inter-anual da precipitação

A variação de anos chuvosos e secos no NEB são influenciados por sistemas atmosféricos dos oceanos Pacífico e Atlântico. Na figura Figura 4 é ilustrada a distribuição das precipitações médias mensais da região. No oceano Pacífico equatorial, quando o ENOS é caracterizado por anomalias positivas, ou seja, águas mais quentes que o normal (El Niño), possui forte conexão com a inibição de formação de nuvens no NEB e podem favorecer eventos de seca. Em contrapartida, em situações de anomalia negativa as condições de águas mais frias no oceano Pacífico (La Niña) mostram-se relacionadas com anos considerados normais, chuvosos ou muito chuvosos no NEB (FERREIRA & MELLO, 2005).

No oceano Atlântico tropical, os campos de TSM atuam sobre a posição latitudinal da ZCIT, influenciando na distribuição das chuvas sobre o NEB, sobretudo na região norte (NOBRE & SHUKLA, 1996; KANE, 1997). A ocorrência de águas mais quentes no Atlântico Norte que o Atlântico Sul (gradiente positivo) tende a desfavorecer as chuvas no NEB através dos movimentos descendentes de ar, conduzidos dos altos níveis atmosféricos para a região norte e central do NEB. Por outro lado, em situações que as águas do Atlântico Norte encontram-se mais frias do que o Atlântico Sul (gradiente negativo), ocorre aumento nos movimentos ascendentes de ar, acentuando a formação de nuvens carregadas no NEB (HASTENRATH & HELLER, 1977; PEZZI & CAVALCANTE, 2001)

Analisando a relação entre os eventos de El Niño e de secas no NEB durante 1849 a 1992, Kane (1997) demonstra que embora muitos anos de El Niño severos e moderados sejam associados a secas severas no NEB, não há uma forte relação entre estes fenômenos, indicando que o ENSO deve ser investigado em conjunto com outros fenômenos nos prognósticos de secas. Kayano e Andreoli (2009, p. 222) apontam que a TSM do Atlântico Tropical é determinante das anomalias da precipitação sobre o NEB, de modo que os ENOS atuam para o seu fortalecimento ou enfraquecimento.

Figura 4 - Precipitação média mensal (mm) para o NEB no período de 2000 a 2018.

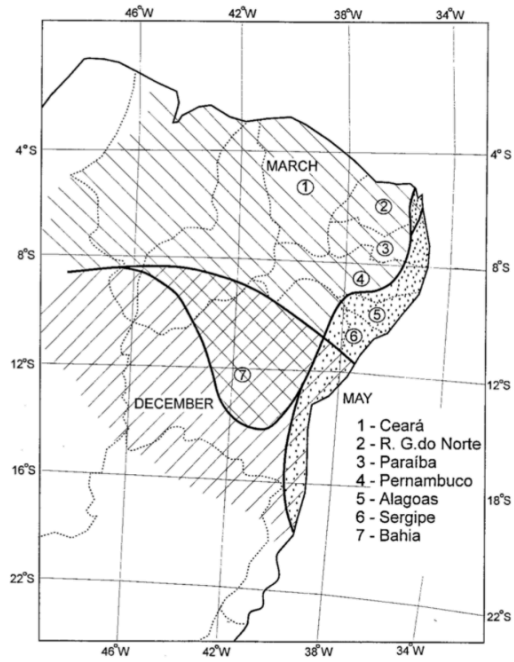


Fonte: Elaborado pela FUNCEME a partir do produto MERGE (CPTEC/INPE).

3.5.2 Variabilidade Intra-anual da precipitação

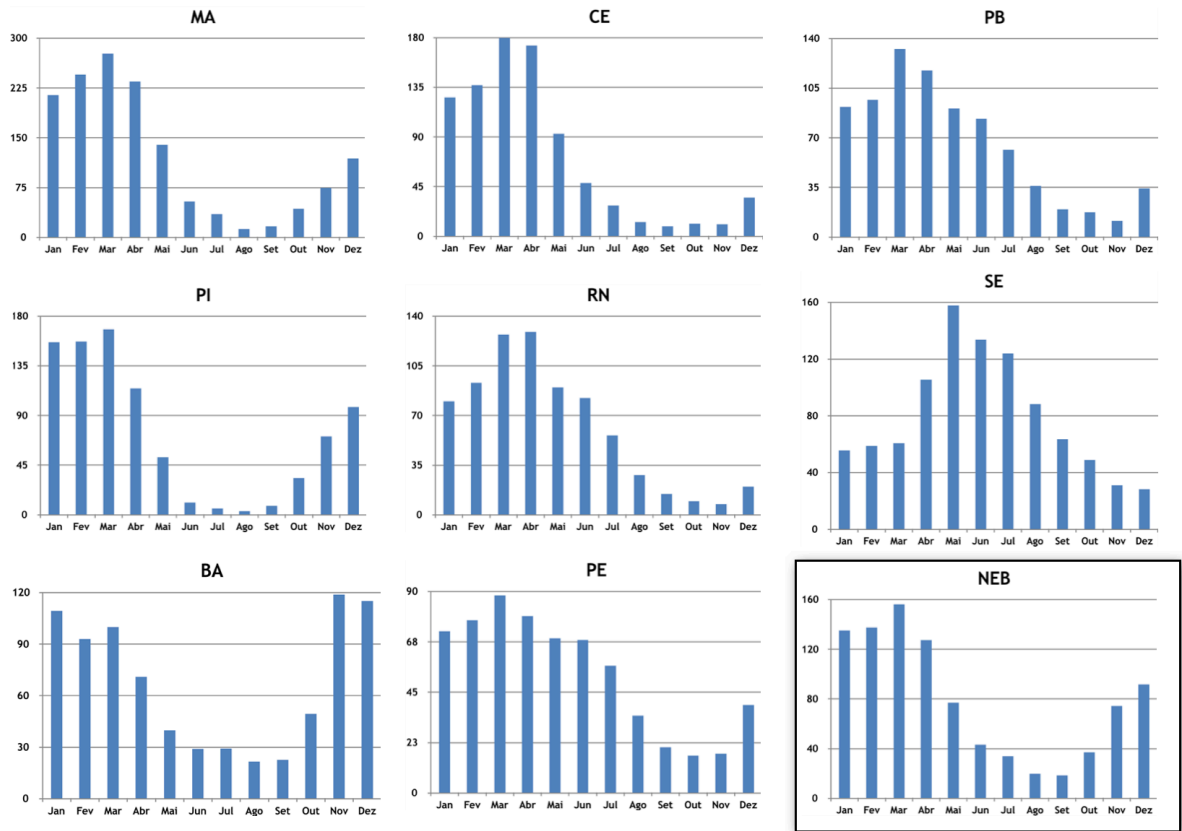
O ciclo anual das precipitações no NEB é influenciado por diferentes sistemas atmosféricos de origem interna ou externa à região. Kousky (1979) ao analisar a média dos máximos mensais da precipitação no NEB, apontou três regiões com distintos regimes de chuva (Figura 5). De certo modo, estes regimes também são evidenciados ao se observar a distribuição da precipitação média mensal nos estados do NEB (Figura 6).

Figura 5 - Regimes de chuva do NEB.



Fonte: Adaptado de Kousky (1979).

Figura 6 - Precipitação média mensal (mm) dos estados do NEB para o período 1998 a 2017.



Fonte: Elaborado pela FUNCEME a partir do produto MERGE (CPTEC/INPE).

A parte norte do NEB possui sua estação chuvosa no quadrimestre janeiro a abril e compreende os estados do Maranhão (MA), Piauí (PI), Ceará (CE), Oeste da Paraíba (PB) e Pernambuco (PE). Modulada pela TSM no Atlântico Tropical, a ZCIT tende a maior proximidade deste setor na sua posição em torno de 4° S (FERREIRA & MELLO, 2005); situação que favorece o transporte de umidade e aumento da convecção sobre a região norte (KAYANO & ANDREOLI, 2009, p.28). É considerada o principal sistema gerador de chuvas para período da estação chuvosa neste setor (UVO, 1989).

Na parte sul, o período mais chuvoso ocorre de novembro a fevereiro e é compreendida pelos estados da Bahia (BA), Sul do MA e PI. O principal sistema atuante nessa região é a ZCAS, que se forma através da intensificação do calor e da umidade resultante dos encontros das massas de ar da Amazônia e do Atlântico Sul (MENDONÇA & DANNI-OLIVEIRA, 2007; NOBRE, 2012). A ZCAS é favorável às chuvas, principalmente na Bahia quando sua faixa de instabilidade se encontra na sua posição mais ao norte.

A parte leste possui seu período chuvoso em abril a julho e abrange o litoral dos estados do Rio Grande do Norte (RN), PB, PE, Alagoas (AL), Sergipe (SE) e BA. Nesta região a precipitação é influenciada pelas Ondas de Leste, que se deslocam da costa da África até o litoral brasileiro e, em menores escalas, pelas brisas marítimas e terrestres (FERREIRA & MELLO, 2005). Outro importante fenômeno são as Frentes Frias, oriundas de altas latitudes do hemisfério sul e se instalam durante o verão ao longo da costa brasileira (entre São Paulo e o Sul da Bahia)

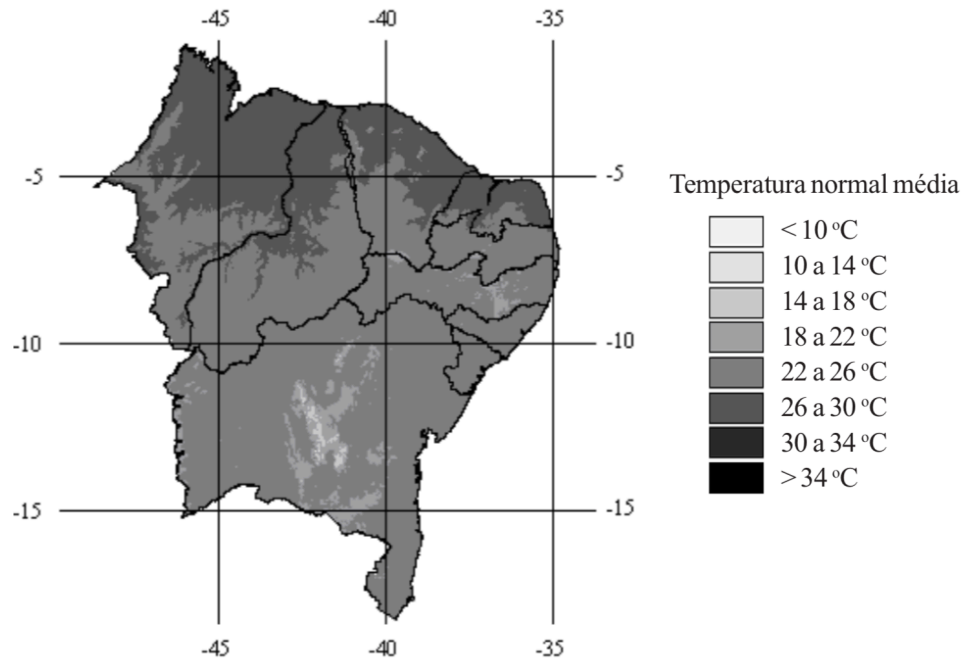
Em escalas espaciais e temporais menores, o fenômeno das Ondas de Madden e Julian (OMJ) atuam sobre todo o NEB. Este consiste em ondas atmosféricas que se propagam do oceano Índico e Pacífico para o leste sobre a América do sul, atuando numa frequência de 30-60 dias (MADDEN & JULIAN, 1971).

3.5.3 Temperatura

Em relação a temperatura, não é encontrado no NEB uma forte variação, sendo caracterizada por uma baixa amplitude térmica de 8 °C. De acordo com Medeiros *et al.* (2005) são encontradas médias anuais das temperaturas do ar que variam entre 18 e 26 °C. As médias anuais inferiores a 20 °C são encontradas na Chapada Diamantina e no Planalto da

Borborema. Os maiores valores encontram-se nas menores latitudes, próximos a faixa equatorial (Figura 7).

Figura 7 - Distribuição das temperaturas médias do ar para o NEB.



Fonte: Medeiros *et al.* (2005).

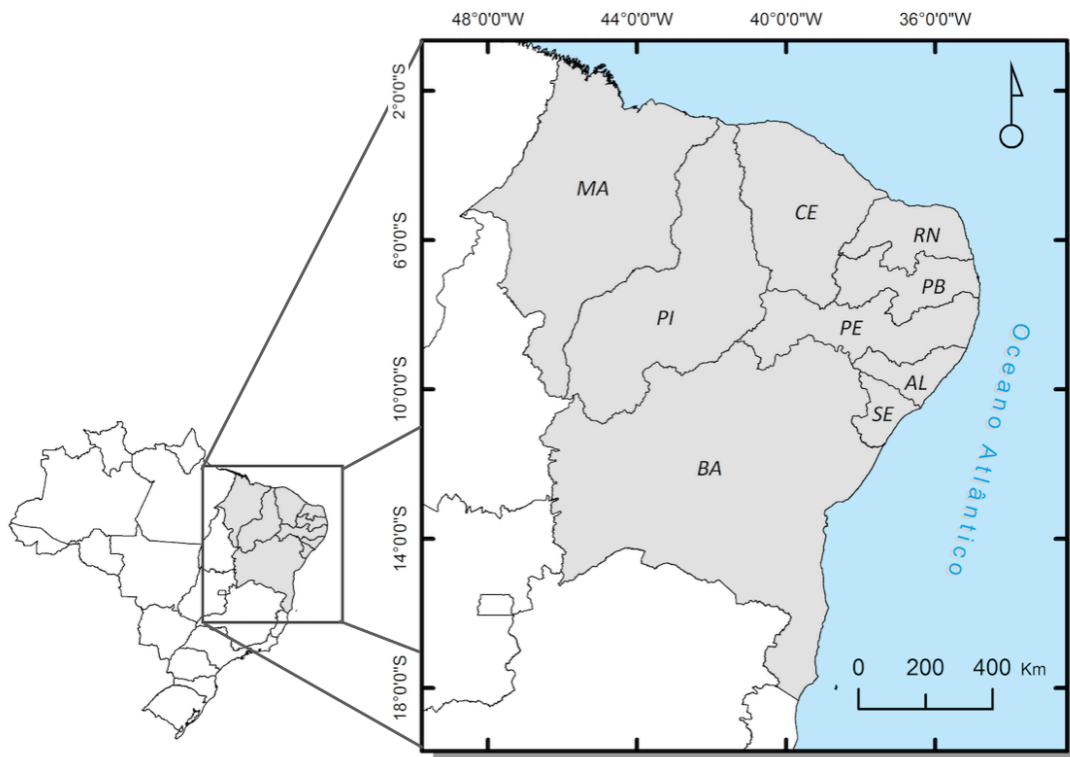
4. ÁREA DE ESTUDO E METODOLOGIA

Esta seção compreende a área de estudo e as ferramentas utilizadas na análise espaço-temporal do NDVI: Dados do sensor MODIS/TERRA referentes ao período de 2000 a 2017, dados de precipitação e medidas de estatística descritiva.

4.1 Área de estudo

A área selecionada para o estudo corresponde à região do Nordeste Brasileiro (NEB), localizada entre as latitudes 1,0° S a 18,3° S e longitudes 34,8° W a 48,7° W, compreendendo os estados do MA, PI, CE, RN, PB, PE, AL, SE e BA (Figura 8). O NEB possui uma extensão de 1.542.000 km² e ocupa aproximadamente 18,3% do território brasileiro (MARENGO *et al.*, 2016).

Figura 8 - Localização da área de estudo.



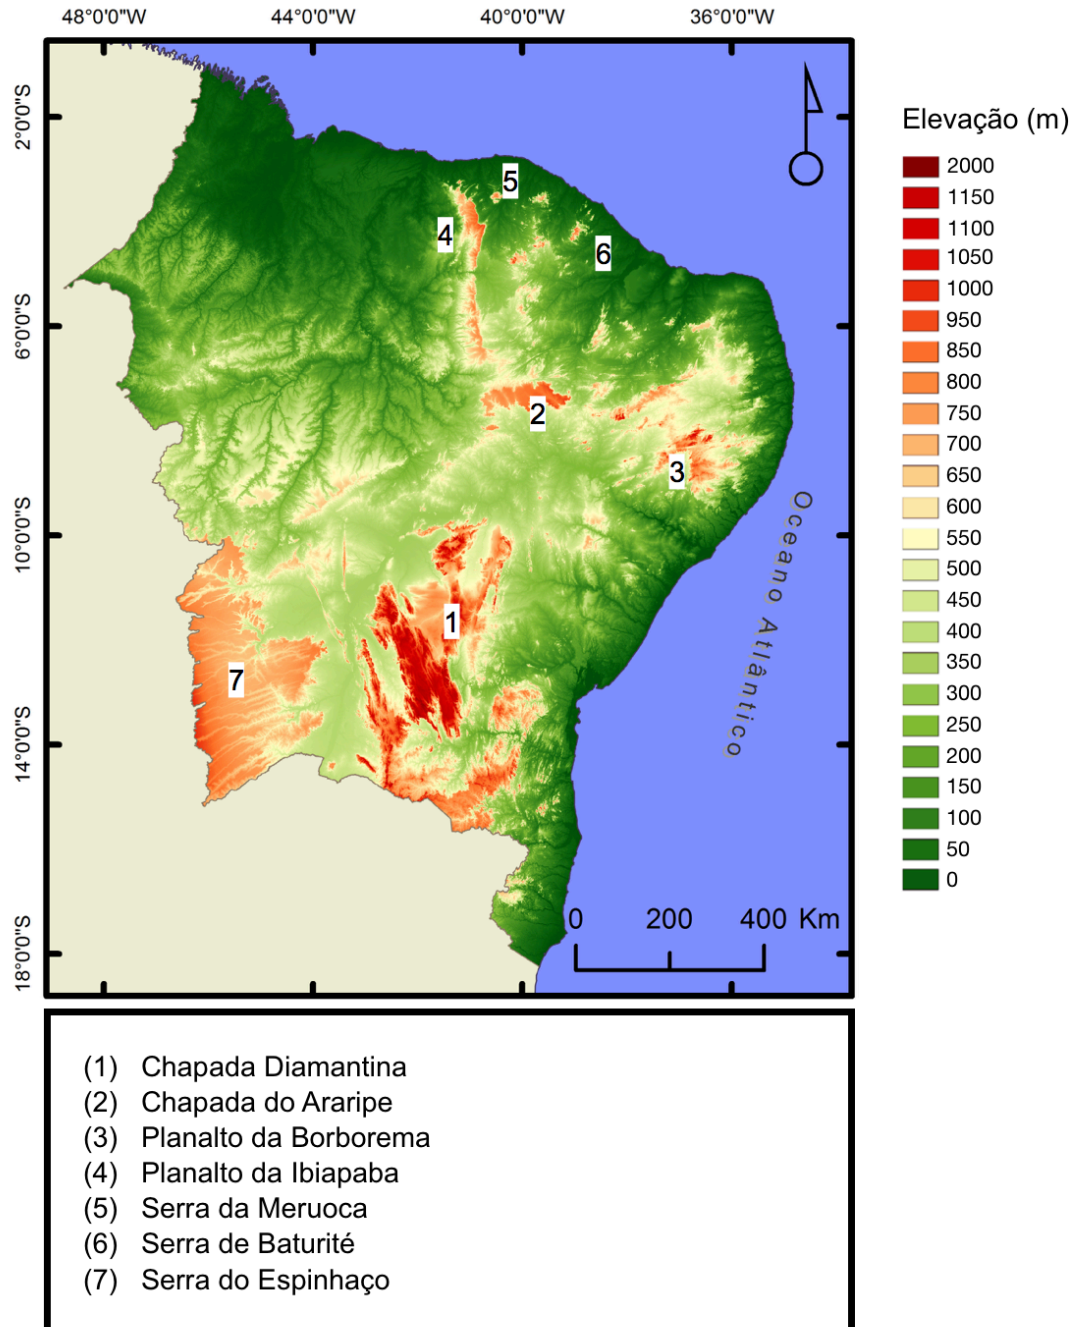
Fonte: Elaborado pelo autor.

O relevo do NEB é constituído por dois antigos e extensos planaltos: o Borborema e a Bacia do Rio Parnaíba. Entre estas regiões encontra-se a depressão sertaneja que abriga em si uma série de maciços residuais, como o de Baturité e a da Meruoca. Ademais, destaca-se as chapadas Diamantina e do Araripe, os planaltos da Borborema e da Ibiapaba (Figura 9).

Em relação à delimitação dos biomas do Brasil (IBGE, 2004a), o NEB abrange: A Amazônia, a Caatinga, o Cerrado e a Mata Atlântica (Figura 10). No noroeste do NEB, a Amazônia é encontrada em conjunto com o clima Equatorial Úmido, compreendendo 34% do território do MA. A Caatinga por sua vez, é distribuída por todo o NEB; Em alguns trechos pode se apresentar em porte arbustivo denso ou esparso, ou em porte florestal nos locais sedimentares. Ao longo da faixa costeira, ocorre a Mata Atlântica, onde apenas poucos remanescentes florestais restam (MORELATTO & HADDAD, 2000). O cerrado compreende o Sul do MA e o oeste da BA, formado pela “Mata de Cocais” onde ocorre forte presença do

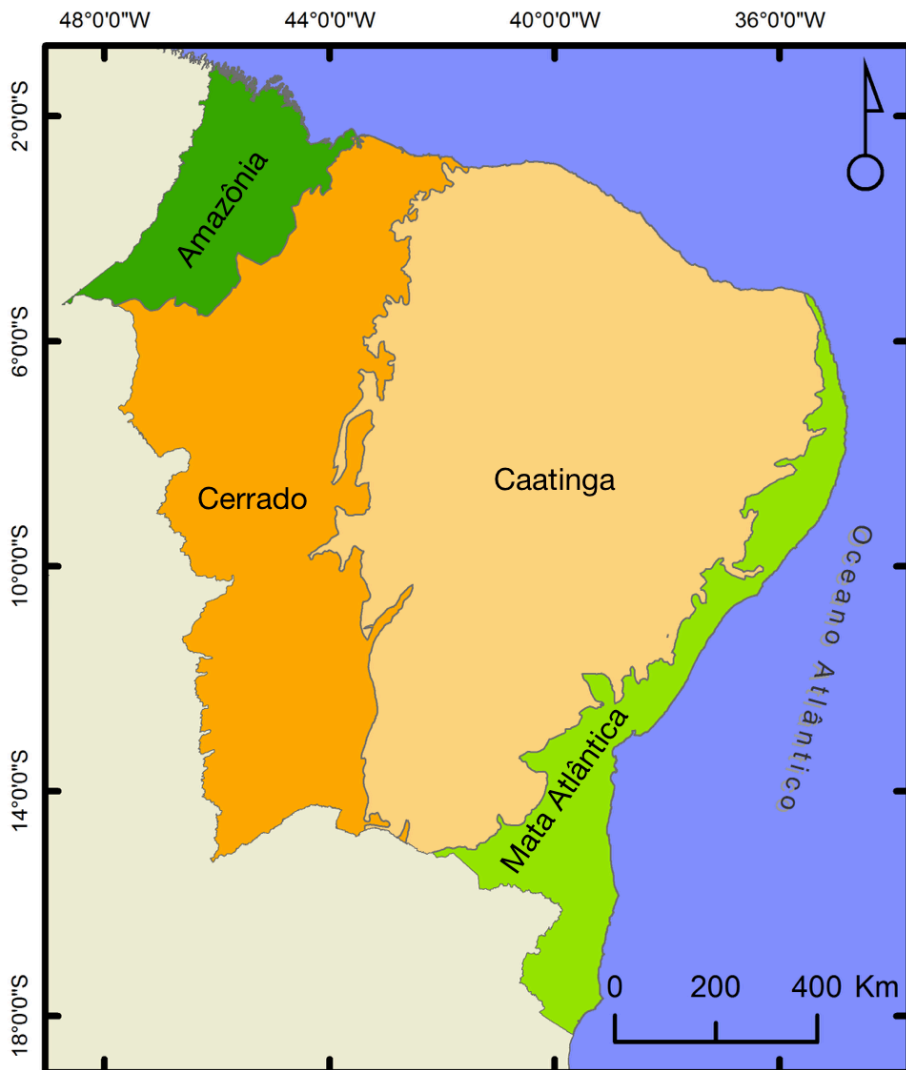
babaçu (*Orbignya oleifera* Burret) e da carnaúba (*Copernicie prunifera*) (VIEIRA *et al.*, 2013).

Figura 9 - Chapadas, Planaltos e Serras sobre o NEB.



Fonte: EMBRAPA. Elaborado pelo autor

Figura 10 - Delimitação dos Biomas do Brasil - IBGE



Fonte: IBGE (2004a). Elaborado pelo autor.

4.2 Rotinas computacionais de aquisição e pré-processamento dos dados

No sentido de facilitar a extração e a manipulação das séries temporais do NDVI, foram desenvolvidas duas rotinas computacionais através de linguagem de programação *python*: A primeira para a aquisição dos dados MODIS (Apêndice A) e a segunda para o pré-processamento das cenas (Apêndice B).

4.2.1 Download dos dados

Neste trabalho foram utilizadas as imagens de NDVI e de confiabilidade do *pixel* (*pixel reliability*) do produto MOD13Q1 do sensor MODIS/TERRA referentes ao período de 18 de fevereiro de 2000 a 31 de dezembro de 2017 na versão mais atualizada (V006). As imagens deste produto são disponibilizadas em projeção sinusoidal e no formato HDF (*Hierarchical Data Format*), possuindo resolução espacial de 250 m, resolução temporal de 16 dias e resolução radiométrica de 16 *bits* para o NDVI e 8 *bits* para as imagens de confiabilidade. Os valores das imagens de NDVI variam de -3000 a 10000 enquanto os de confiabilidade variam de -1 a 3, sendo ordenados em relação à qualidade do *pixel* (DIDAN *et al.*, 2015). Neste trabalho, somente os *pixels* de valor 3, que se referem à presença de nuvens, foram utilizados na análise de confiabilidade (Tabela 2). Para cobrir a extensão do NEB, quatro cenas foram necessárias: h13v09, h13v10, h14v09 e h14v10; totalizando um total de 1644 imagens NDVI e 1644 imagens de confiabilidade (ver metodologia abaixo).

Tabela 2 - Descrição da imagem de confiabilidade (*pixel reliability*) do produto MOD13Q1.

| Valor do Pixel | Resumo QA | Descrição |
|----------------|---------------|--------------------------------------|
| -1 | Sem Dado | Não Processado |
| 0 | Dado Bom | Uso com confiança |
| 1 | Dado Marginal | Utilizável, porém consultar outro QA |
| 2 | Neve/Gelo | Alvo coberto com neve/gelo |
| 3 | Nuvem | Alvo coberto com nuvens |

Fonte: Moraes e Rocha (2011).

Para realizar este procedimento de forma automatizada, uma rotina foi escrita utilizando o módulo *downmodis* da biblioteca de código aberto *pymodis*. O *download* das imagens é feito via FTP (*File Transfer Protocol*), de forma gratuita, através da base de dados do *Land Processes Distributed Active Archive Center* (LP-DAAC), encontrada em <<https://e4ftl01.cr.usgs.gov/MOLT/>>.

Para a seleção e transferência dos dados a rotina requer a modificação de alguns parâmetros pelo usuário, e compreendem: a Pasta de destino dos arquivos, os anos das

imagens desejadas (ano mínimo e ano máximo), as credenciais NASA *Earthdata* (registro gratuito em <<https://urs.earthdata.nasa.gov/users/new>>), as cenas escolhidas, o produto requerido e sua versão (por exemplo: “MOD13Q1.006”).

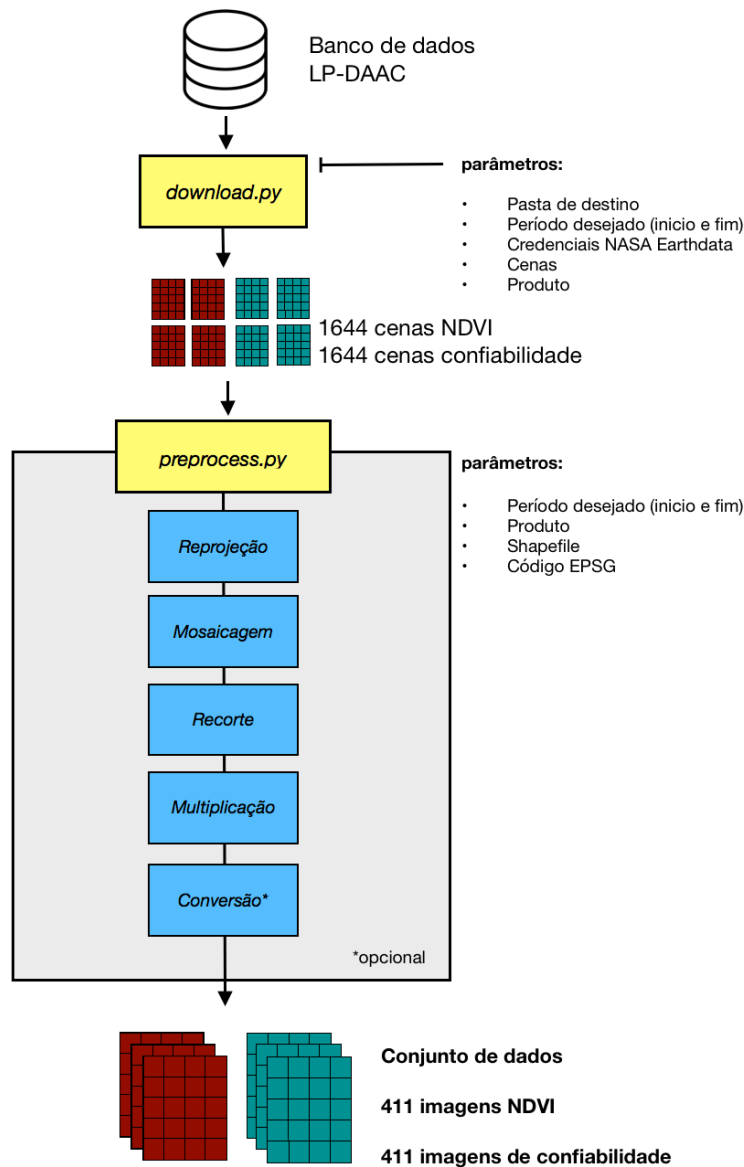
O conjunto de dados obtido é estruturado em pastas referentes aos anos das imagens e contém no nome dos arquivos uma numeração que identifica o dia do ano referente a cada imagem (dia juliano). Na Tabela 3 é demonstrada o dia do ano das imagens, o respectivo período que a composição abrange e a quantidade de imagens adquiridas.

Tabela 3 - Período e quantidade de imagens referente ao dia do ano das imagens MODIS.

| Dia do Ano (dia juliano) | Período | Quantidade de Imagens |
|-------------------------------------|-----------------|----------------------------------|
| 1 | 01/Jan a 16/Jan | 17 |
| 17 | 17/Jan a 01/Fev | 17 |
| 33 | 02/Fev a 17/Fev | 17 |
| 49 | 18/Fev a 04/Mar | 18 |
| 65 | 05/Mar a 20/Mar | 18 |
| 81 | 21/Mar a 05/Abr | 18 |
| 97 | 06/Abr a 21/Abr | 18 |
| 113 | 22/Abr a 07/Mai | 18 |
| 129 | 08/Mai a 23/Mai | 18 |
| 145 | 24/Mai a 08/Jun | 18 |
| 161 | 09/Jun a 24/Jun | 18 |
| 177 | 25/Jun a 10/Jul | 18 |
| 193 | 11/Jul a 26/Jul | 18 |
| 209 | 27/Jul a 11/Ago | 18 |
| 225 | 12/Ago a 27/Ago | 18 |
| 241 | 28/Ago a 12/Set | 18 |
| 257 | 13/Set a 28/Set | 18 |
| 273 | 29/Set a 14/Out | 18 |
| 289 | 15/Out a 30/Out | 18 |
| 305 | 31/Out a 15/Nov | 18 |
| 321 | 16/Nov a 01/Dez | 18 |
| 337 | 02/Dez a 17/Dez | 18 |
| 353 | 18/Dez a 31/Dez | 18 |

Fonte: Elaborado pelo autor.

Figura 11 - Etapas de aquisição e pré-processamento dos dados MODIS.



Fonte: Elaborado pelo autor.

4.2.2 Pré-processamento

Uma rotina baseada nas ferramentas das bibliotecas *numpy*, *GDAL* e *pymodis* foi construída à fim de automatizar o pré-processamento das imagens. O pré-processamento se realiza através de uma função com as seguintes etapas: Reprojeção, mosaicagem, recorte para a área de interesse, multiplicação pelo fator de escala e conversão para formato NetCDF (opcional) (Figura 11). Para a utilização desta rotina, faz-se necessária a modificação das variáveis do ano mínimo e máximo desejado, da identificação produto (por exemplo:

“MOD13Q1”), da pasta de destino, do caminho do arquivo *shapefile* com a delimitação da área de recorte. Ainda, há a opção de modificar parâmetros da função para a escolha do Sistema de Referência de Coordenadas (SRC) a ser usado na reprojeção através do código EPSG², como também para a remoção dos arquivos gerados ao longo das etapas, gerando menor volume de dados e retornando apenas as imagens finais.

Através da rotina, as imagens foram reprojctadas para SIRGAS 2000 (EPSG 4674) utilizando o módulo *convertmodis_gdal* a fim de compatibilizá-las aos outros dados utilizados neste estudo. Em sequência, as 4 cenas referentes ao NEB foram utilizadas para a geração de uma única imagem através da ferramenta *gdal_translate*. Um recorte foi feito para a área de interesse utilizando o *shapefile* dos limite estaduais do NEB, por meio da ferramenta *gdalwarp*.

Devido a fins de compactação dos arquivos, as imagens do NDVI são originalmente disponibilizadas em números inteiros e fora da escala do NDVI (-1 a +1); Por isso faz-se necessária a multiplicação das imagens por seu fator de escala (0.0001). Com essa multiplicação, os valores dos *pixels* fora da área de estudo resultam em -0.3 (valor de preenchimento). Ao fim destas etapas, foram obtidas 411 imagens de NDVI e 411 imagens de confiabilidade do *pixel* (Figura 11) em formato GeoTIFF, com cada uma possuindo 8747 linhas e 7058 colunas.

Para a avaliação do tempo necessário para executar a rotina de pré-processamento, buscou-se averiguar o tempo computacional utilizando as duas opções de formato (GeoTIFF e NetCDF) para 4 selecionados produtos MODIS: MOD13Q1, MOD13A2, MOD13A3 e MOD11A2.

4.3 Dados de precipitação

Para fins de comparação visual com os dados NDVI, foram utilizados dados de precipitação do produto MERGE referente ao mesmo período de análise (2000-2017). O MERGE possui resolução espacial de 0.25° (aproximadamente 28 km) e é formado a partir da combinação de dados de precipitação estimados pelo satélite *Tropical Rainfall Measuring*

² o código EPSG foi criado pelo Grupo de Pesquisa Petrolífera Européia na intenção de sistematizar os SRCs existentes no mundo.

Mission (TRMM) com dados observacionais de pluviômetros do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), do Instituto Nacional de Pesquisas Espaciais (INPE) e de estações climáticas do *Global Telecommunication System* (GTS) (Rozante *et al.*, 2010). Os dados de precipitação foram recortados para o NEB, acumulados a cada 16 dias e espacializados através das precipitações médias (ver metodologia abaixo).

4.4 Filtragem

Tendo em vista que valores de NDVI negativos tendem a ser representativos de água, torna-se necessária sua remoção em estudos de vegetação (SINGH *et al.*, 2003; JIANBO *et al.*, 2014). Neste caso, para cada imagem os valores negativos foram filtrados aplicando uma máscara binária através do *numpy*, removendo assim os *pixels* fora da área de estudo (valores -0.3).

Além disso, para evitar que *pixels* de água sejam utilizados nas análises, foi empregada uma máscara adicional para os espelhos d'água do NEB. Essa filtragem foi realizada utilizando dados vetoriais do Mapeamento dos Espelhos d'água do Brasil, disponíveis no portal GeoNetwork³ da Agência Nacional de Águas (ANA). O mapeamento inclui espelhos d'água acima de 20 ha e são compatíveis com a escala 1:250000 (MI, 2008, p. 76). Com o uso do ArcGIS 10.3 (a partir de licença adquirida pela FUNCEME), os dados vetoriais dos espelhos d'água foram convertidos para *raster* de mesmo tamanho de *pixel* das imagens de NDVI. Posteriormente os valores foram reclassificados com valor 0 para água e 1 para o restante e, em sequência, exportou-se a imagem em formato *tif* com a mesma extensão (linhas e colunas) das imagens NDVI. Por fim, essa imagem foi aplicada como máscara adicional para o NDVI.

Em posse dos dados filtrados, estes foram arranjados em matrizes tridimensionais (3D) representantes de cada dia do ano, consistindo de eixos de tempo (18 ou 17 anos), latitude (8747 linhas) e longitude (7058 colunas).

³ disponível no endereço:

<<http://metadados.ana.gov.br/geonetwork/srv/pt/main.home?uuid=7d054e5a-8cc9-403c-9f1a-085fd933610c>>

4.5 Análise de confiabilidade

Com o fim de identificar a ocorrência de falhas por nuvens, a análise se dá por duas vias: A primeira por séries temporais das matrizes 3D da confiabilidade referentes a cada dia do ano, em que foram contabilizados os *pixels* representantes de nuvens (valor 3) e os *pixels* totais de confiabilidade. A segunda via se dá pelas séries temporais no eixo dos anos das matrizes 3D de confiabilidade. Nas séries temporais adquiridas foi aplicada a Equação 2:

$$PCT(\%) = \frac{x}{N} \times 100 \quad (2)$$

onde x é a quantidade total de *pixels* representantes de nuvem na série e N é a quantidade total de *pixels* de confiabilidade.

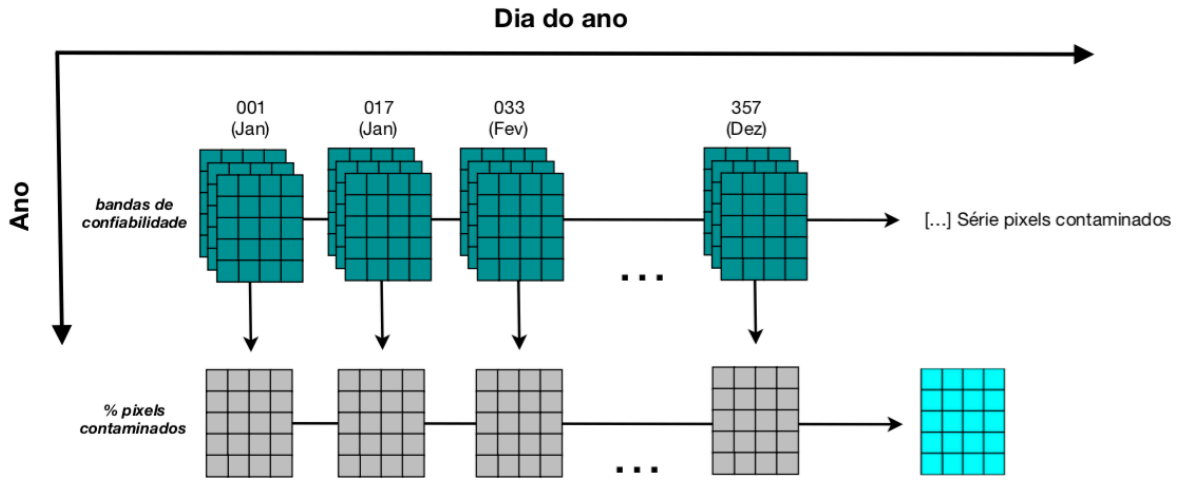
Ao fim, as matrizes bidimensionais das porcentagens foram plotadas em figuras através do módulo *basemap*. A Figura 12 ilustra a o acesso às séries temporais desta etapa.

4.6 Análise espaço-temporal do NDVI

Para as séries temporais extraídas das matrizes 3D do NDVI, foram empregadas medidas de estatística para a identificação de padrões espaço-temporais da vegetação. Foram aplicadas medidas de mínimos, médios, máximos, coeficiente de variação (CV), anomalia padronizada (escore-z) e média móvel tanto nas séries temporais dos anos como entre os períodos do dia do ano (Figura 13).

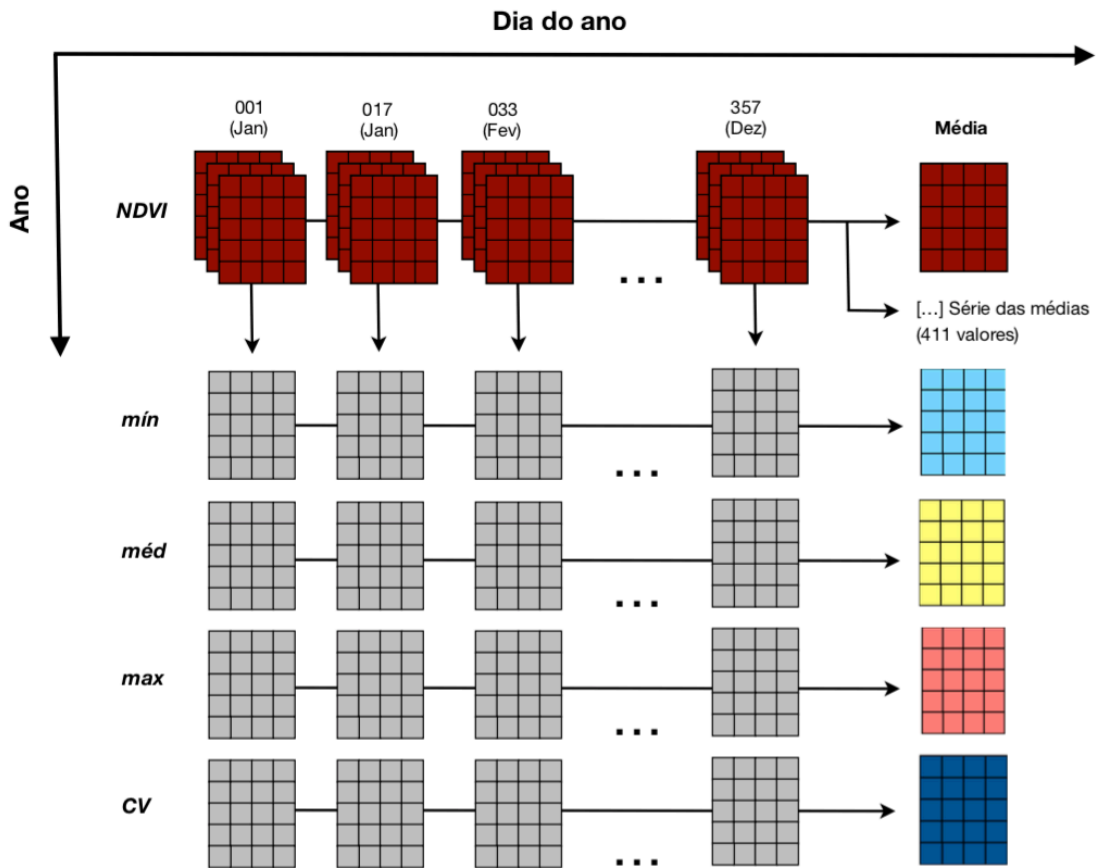
Para as medidas de mínimos, médios, máximos e CV, a extração da informação foi utilizada para construir curvas da variação intra-anual da vegetação, enquanto as medidas de anomalia padronizada e média móvel são utilizadas nas identificação dos padrões temporais e de tendência de crescimento vegetativo (SCHUCKNECHT *et al.*, 2013).

Figura 12 - Obtenção das séries temporais dos *pixels* contaminados.



Fonte: Elaborado pelo autor.

Figura 13 - Obtenção das séries temporais do NDVI.



Fonte: Elaborado pelo autor.

Os valores mínimos indicam a pior situação da vegetação (por exemplo, estresse hídrico), enquanto os valores máximos refletem as melhores condições (plena atividade fotossintética). O valor médio, por sua vez, indica o comportamento médio da vegetação e é calculado pela Equação 3:

$$\bar{x}(x, y) = \frac{x(x, y)_1 + x(x, y)_2 + \dots + x(x, y)_n}{N(x, y)} \quad (3)$$

onde x são os valores da série e N o número total de valores na série no espaço x, y (x = longitude, y = latitude).

O CV é uma medida que representa a magnitude da variabilidade do NDVI. O seu cálculo se dá com a Equação 4:

$$CV(x, y) = \frac{\sigma NDVI(x, y)}{\mu NDVI(x, y)} \times 100 \quad (4)$$

onde $\sigma NDVI(x, y)$ é o desvio padrão da série e $\mu NDVI(x, y)$ é a média da série no espaço x, y (x = longitude, y = latitude).

De acordo com TAN *et al.* (2001), dados de observação da terra costumam possuir ciclos sazonais, tornando-se necessária a remoção de seus componentes antes que se examine tendências de crescimento ou declínio. Nesse sentido, o escore-z foi utilizado na série das médias das imagens do NDVI e nos dados de precipitação, expressando para cada valor da séries temporais o seu desvio em relação a média histórica. O seu cálculo se realiza pela Equação 5:

$$Z = \frac{OBS - \mu}{\sigma} \quad (5)$$

onde OBS representa o valor a ser observado, μ é a média da série e σ o desvio padrão da série.

Para a identificação de tendências, médias móveis de 3 anos foram calculadas para as séries do escore-z, a seguir pela Equação 6:

$$MM3 = \frac{P_i + P_{i+1} \dots + P_{i+n-1}}{N} \quad (6)$$

em que P são os valores observados de anomalia padronizada na série para um determinado período e N é o número de períodos de 16 dias em 3 anos ($23 \times 3 = 69$ períodos).

Por fim, os valores do CV, do NDVI médio e da precipitação acumulada média foram plotados em figuras para cada períodos dos dias dos anos (16 dias), para todo o ano e, buscando maior representatividade, para as médias dos dias do ano que sobrepõem os trimestres de maior e menor precipitação média do NEB (ver Figura 6). Neste último caso, os dias do ano 065-145 representam o trimestre mar-abr-mai e os dias do ano 209-289 o trimestre ago-set-out.

5. RESULTADOS E DISCUSSÕES

5.1 Desempenho das rotinas

Na Tabela 4 se observa uma vantagem computacional aos produtos de menor resolução espacial e menor resolução temporal; O produto MOD13Q1 necessitou 19 vezes mais tempo de processamento do que o produto MOD13A3, utilizando como formato final o NetCDF. Os processos ocorreram sem apresentar sobrecarga e não comprometeram o funcionamento do computador.

As rotinas desenvolvidas possuem finalidade generalista, isto é, podem ser utilizadas para a aquisição e pré-processamento de outros produtos MODIS. Dessa maneira, as rotinas podem ser empregadas, como exemplo, em produtos como os de reflectância superficial (MOD09), temperatura da superfície (MOD11) e aos índices de vegetação NDVI e EVI (MOD13) de diferentes resoluções espaciais e temporais.

Tabela 4 - Tempo Computacional para produtos MODIS selecionados com escolha de formato final GeoTIFF e NetCDF.

| Produto | | Resolução espacial | Resolução temporal | Resolução radiométrica | Tamanho (x, y) | Quantidade de cenas processadas | Tempo formato final GeoTIFF | Tempo formato final NetCDF |
|---------|-------------|--------------------|--------------------|------------------------|----------------|---------------------------------|-----------------------------|----------------------------|
| MOD13Q1 | NDVI | 250 m | 16 dias | 16 bits | 4800, 4800 | 1644 | 464m 8s | 538m 32s |
| MOD11A2 | Temperatura | 1000 m | 8 dias | 16 bits | 1200, 1200 | 3152 | 83m 50s | 92m 7s |
| MOD13A2 | NDVI | 1000 m | 16 dias | 16 bits | 1200, 1200 | 1644 | 54m 23s | 57m 58s |
| MOD13A3 | NDVI | 1000 m | 1 mês | 16 bits | 1200, 1200 | 860 | 23m 11s | 28m 5s |

Nota: A quantidade de cenas processadas correspondem ao período de 2000 a 2017. A máquina utilizada possui Intel Core i5-2310, 2.9GHz e 4GB RAM.

Fonte: elaborado pelo autor

5.2 Confiabilidade do NDVI

Foi observado para todo o período analisado (411 imagens) um percentual de 16.3% de *pixels* de NDVI contaminados por nuvens. As porcentagens encontradas variaram de 6.0 a 32.7% para cada dia do ano, apresentando maiores percentuais nos dias do ano 1 a 97 e menores percentuais nos dias do ano 177 a 241 (Tabela 5).

Na Figura 14a se observa o período de maior porcentagem de *pixels* falhos (32.7%). Na maior parte do estado do MA, percebeu-se áreas com falhas de 60 a 100% da série temporal, enquanto regiões interioranas apresentam falhas nas séries temporais menores que 40%. Assim, se observa que dependendo do período e da área analisada, a extração de informações da vegetação nas séries temporais pode ser prejudicada por completo. Mesmo no período de menor porcentagem de falhas (6.0%), os *pixels* defeituosos ainda se concentram sobre as mesmas áreas (Figura 14b), indicando que as falhas persistem nessas regiões ao longo do ano.

A Figura 14c ilustra a média de porcentagem de *pixels* falhos para todo o período analisado neste trabalho. Constata-se que áreas de maiores falhas, com médias acima de 40% das séries temporais comprometidas, se apresentam no MA, na faixa costeira do CE, RN, PB, PE, AL e BA e nas serras úmidas no CE. A distribuição espacial das falhas para todos os dias do ano são demonstradas nas figuras do Apêndice C.

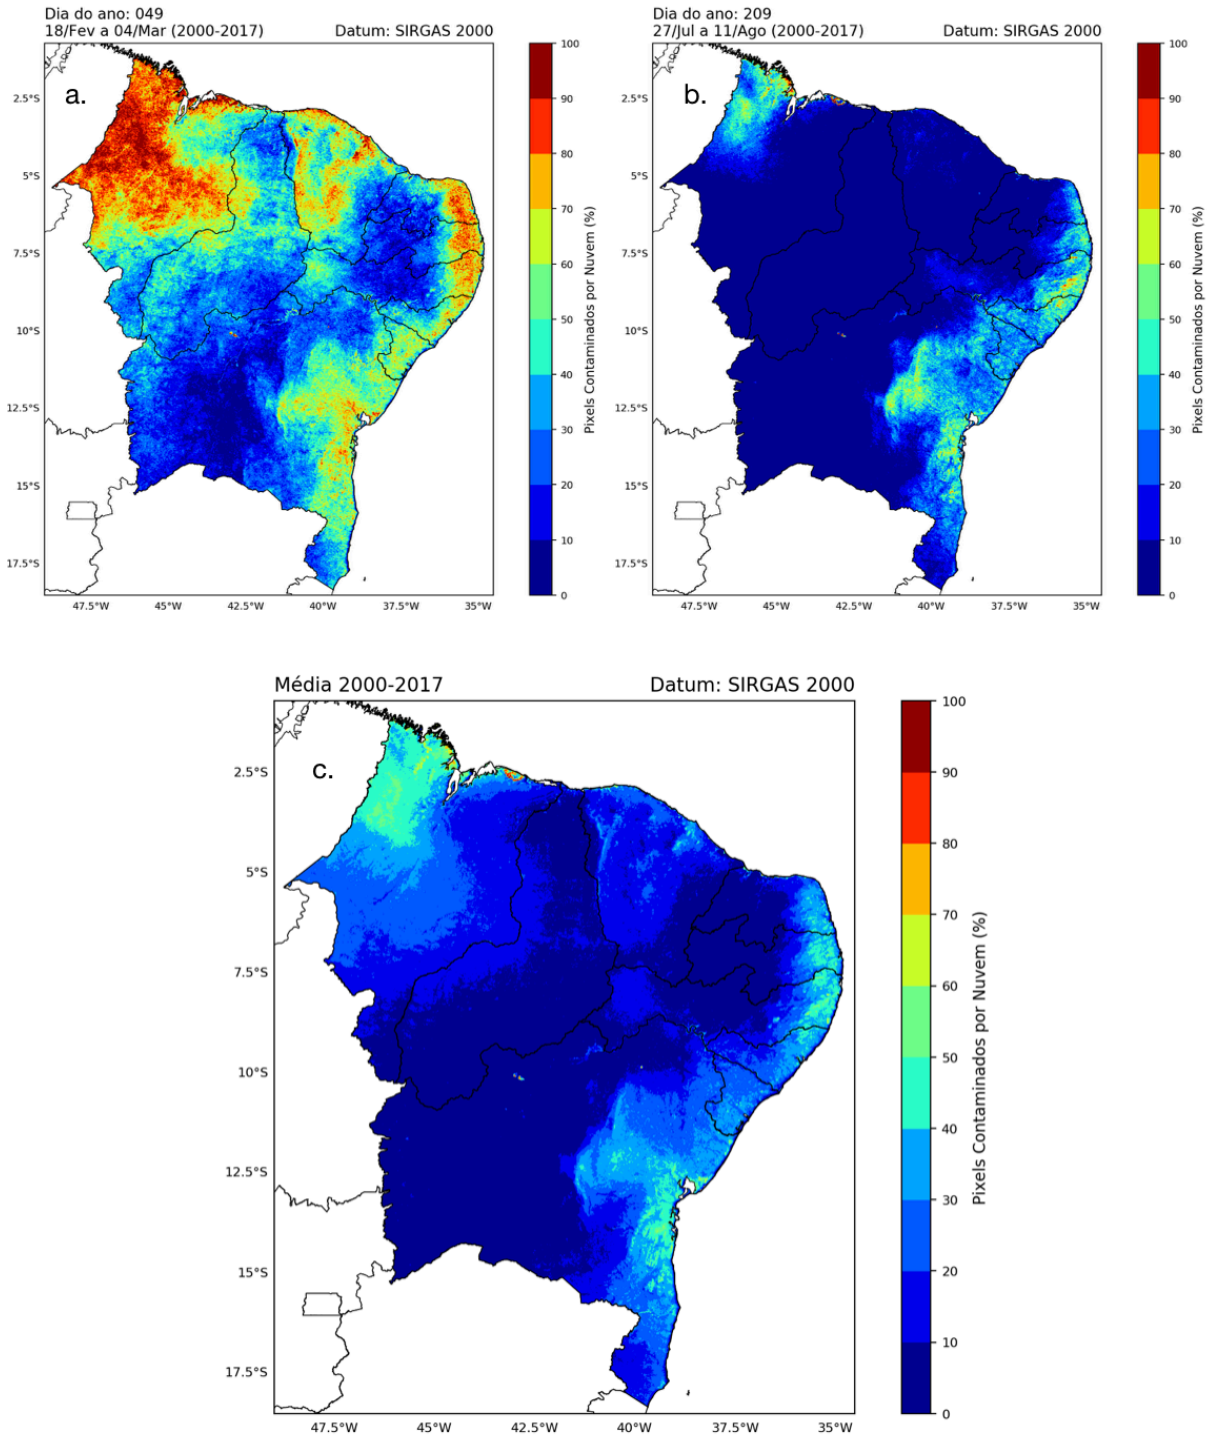
Tabela 5 - Porcentagem de pixels contaminados nas imagens de NDVI analisadas.

| Dia do Ano (dia juliano) | Período | Quantidade de Imagens | Quantidade de <i>Pixels</i> NDVI | Quantidade de <i>Pixels</i> Contaminados | % <i>Pixels</i> Contaminados |
|-------------------------------------|-----------------|----------------------------------|---|---|---|
| 1 | 01/Jan a 16/Jan | 17 | 549530402 | 136048477 | 24.8% |
| 17 | 17/Jan a 01/Fev | 17 | 548755273 | 174509422 | 31.8% |
| 33 | 02/Fev a 17/Fev | 17 | 548946787 | 151810741 | 27.7% |
| 49 | 18/Fev a 04/Mar | 18 | 580288551 | 189556449 | 32.7% |
| 65 | 05/Mar a 20/Mar | 18 | 579825960 | 182549887 | 31.5% |
| 81 | 21/Mar a 05/Abr | 18 | 580077719 | 178958662 | 30.9% |
| 97 | 06/Abr a 21/Abr | 18 | 580136681 | 148322919 | 25.6% |
| 113 | 22/Abr a 07/Mai | 18 | 581411525 | 100010109 | 17.2% |
| 129 | 08/Mai a 23/Mai | 18 | 582039637 | 66820241 | 11.5% |
| 145 | 24/Mai a 08/Jun | 18 | 582502548 | 45175370 | 7.8% |
| 161 | 09/Jun a 24/Jun | 18 | 582535543 | 49449261 | 8.5% |
| 177 | 25/Jun a 10/Jul | 18 | 582517227 | 44536496 | 7.6% |
| 193 | 11/Jul a 26/Jul | 18 | 582649370 | 40292791 | 6.9% |
| 209 | 27/Jul a 11/Ago | 18 | 582941871 | 34719909 | 6.0% |
| 225 | 12/Ago a 27/Ago | 18 | 583016519 | 40274980 | 6.9% |
| 241 | 28/Ago a 12/Set | 18 | 583218322 | 43057513 | 7.4% |
| 257 | 13/Set a 28/Set | 18 | 583479030 | 44674116 | 7.7% |
| 273 | 29/Set a 14/Out | 18 | 551108734 | 52103001 | 9.5% |
| 289 | 15/Out a 30/Out | 18 | 583542525 | 61674111 | 10.6% |
| 305 | 31/Out a 15/Nov | 18 | 583313827 | 81627191 | 14.0% |
| 321 | 16/Nov a 01/Dez | 18 | 583157280 | 87046841 | 14.9% |
| 337 | 02/Dez a 17/Dez | 18 | 582680656 | 113063261 | 19.4% |
| 353 | 18/Dez a 31/Dez | 18 | 584598956 | 93160401 | 15.9% |

Soma: 411 13262274943 2159442149 **16.28%**

Fonte: Elaborado pelo autor.

Figura 14 - Distribuição espacial dos *pixels* falhos: (a) Dia do ano 49; (b) Dia do ano 209; (c) Médias anuais.



Fonte: Elaborado pelo autor.

5.3 Análise espaço-temporal do NDVI

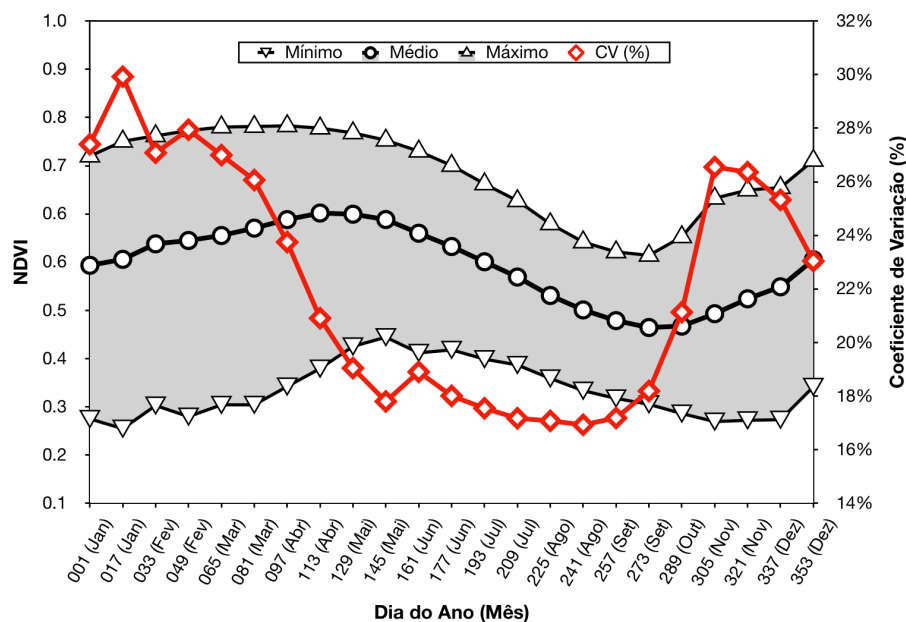
5.3.1 Variabilidade temporal

Nesta seção serão analisadas as variações do NDVI adentre os anos (intra-anual) e ao longo dos anos (interanual).

5.3.1.1 Variabilidade intra-anual

A Figura 15 mostra a variabilidade intra-anual dos valores máximos, médios e mínimos do NDVI nos dias do ano para o período de 2000 a 2017, onde cada ponto das curvas representam uma média de 18 anos (ou 17 anos nos dias do ano 1, 17 e 33 - ver Tabela 5).

Figura 15 - Curvas mínima, média, máxima e CV para o NDVI no NEB durante período 2000 a 2017.



Fonte: Elaborado pelo autor.

Observando a curva média do NDVI, ocorre um ciclo anual que se caracteriza por um período de aumento de atividade fotossintética nos os meses de Setembro a Abril, com

decréscimo do índice ao longo de Maio a Agosto. A curva máxima apresenta um pico nos meses de Março e Abril (0.80) e mínimo no mês de Setembro (0.56). Similarmente, a curva média possui o maior valor de NDVI em Abril (0.64) e menor valor em Setembro (0.42). Entretanto, este padrão não se aplica à curva mínima, ocorrendo um pico do NDVI em Maio (0.41) e menor valor na segunda quinzena de Janeiro (0.24). Dessa forma, se verifica nas três curvas um padrão senoidal, mostrando-se relacionadas à estação chuvosa e à estação seca.

A curva do CV por sua vez, varia entre 16% a 28% e apresenta relação com o tamanho da faixa entre as curvas máxima e mínima. O maior valor encontrado ocorreu na segunda quinzena de Janeiro (28%). Ao aproximar-se do período seco, ocorre menor amplitude entre as curvas e menores valores do CV são encontrados: 16%-17% nos meses de Julho a Setembro.

O salto dos valores de CV a partir de setembro coincidem com o aumento da precipitação média no NEB (ver Figura 6), evidenciando uma rápida resposta do NDVI às chuvas. Além disso, os altos valores de CV encontrados a partir do período chuvoso indicam que a atuação de sistemas climáticos no NEB estão associadas ao aumento da variabilidade da vegetação, que é compreendida pela rápida resposta da vegetação de caatinga.

5.3.1.2 Variabilidade interanual

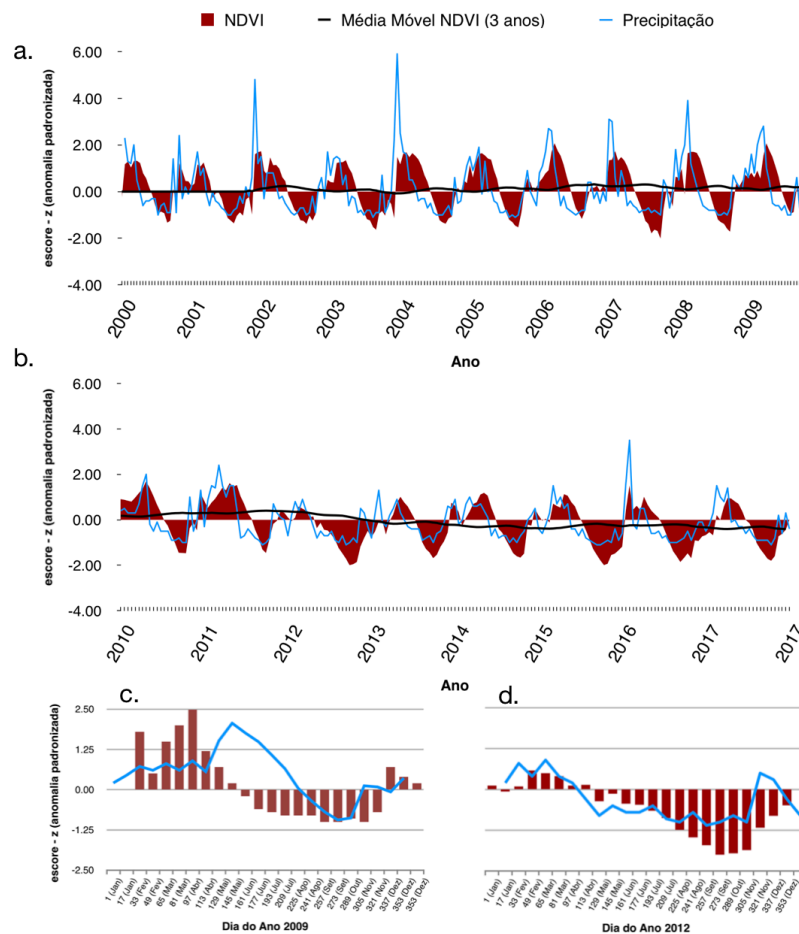
Nas Figuras 16a e 16b é demonstrado o escore-z, que indica o desvio do NDVI em relação à média da série, calculados a partir da média de cada imagem do NDVI durante 18 anos (2000 - 2017). A série temporal do NDVI apresentou uma média 0.54 e desvio padrão de 0.08. De forma geral, observa-se uma forte variação do NDVI ao longo dos anos, acompanhando as oscilações da chuva sobre o NEB. Barbosa *et al.* (2006) ao analisar as anomalias positivas no período 1982-2002 verificou uma tendência positiva nos anos de 1984 a 1991 e uma tendência negativa em 1993 a 1999. Neste trabalho se verifica que o período 2000-2011 é marcado por uma leve tendência positiva do NDVI, ainda com um leve desvio negativo nos anos de 2003 e 2004. Já nos anos 2012-2017 os resultados indicam tendência negativa do NDVI, apresentando períodos positivos mais curtos e de menor magnitude.

Nas Figuras 16c e 16d observa-se em maior detalhes essa variação para dois anos de situações extremas. O ano de 2009 foi marcado por valores de NDVI acima da média em

78% do ano, apresentando máximo desvio no mês de maio (2.07). Por outro lado, no ano de 2012 apenas em 30% do ano foram encontrados desvios positivos.

Esse longo período de crescimento vegetativo em 2009 coincidiu com eventos de forte La Niña nos anos de 2007-2008. Por outro lado, a quebra abrupta no crescimento da vegetação em 2012 não se mostra associada, de início, ao fenômeno de El Niño. Se verifica que estas condições se intensificaram a partir de águas anormalmente quentes sobre o norte do Oceano Atlântico Tropical, que favoreceram o posicionamento da ZCIT mais ao norte (desfavorável às chuvas) e, somando-se ao forte evento de El Niño em 2015-2016, inibiram a formação de atividades convectivas sobre o NEB (MARENGO *et al.*, 2016; MARENGO *et al.*, 2018). Ressalta-se que em 2012 o dipolo variou entre 0,24 a 1,79 °C, indicando águas mais quentes na bacia norte do Oceano Atlântico Tropical.

Figura 16 - Escore z do NDVI, média móvel do NDVI e Precipitação acumulada: **(a)** Anos 2000-2009; **(b)** Anos 2010-2017; **(c)** Ano de 2009; **(d)** Ano de 2012.



Fonte: elaborado pelo autor.

5.3.2 Padrões espaciais

A distribuição espacial do NDVI e do coeficiente de variação serão analisadas nesta seção.

5.3.2.1 Distribuição espacial do NDVI

Nas Figuras 17a e 17d são representadas as médias do NDVI e da Precipitação para os dias do ano 065 a 145 (equivalentes ao trimestre mar-abr-mai) no período de 2000 a 2017. Como foi observado anteriormente, a partir do início do período chuvoso (Figura 6), o NDVI tende a aumentar sobre o NEB e, de forma espacial, são encontrados valores mais elevados (> 0.6) na maior parte do NEB. Mesmo no melhor momento de atividade fotossintética, se observam valores abaixo de 0.5, sobretudo na região norte da BA e no sertão de AL, SE, PE e PB. De forma análoga, nestas regiões ocorrem menores valores de precipitação média.

As médias do NDVI e da Precipitação no trimestre ago-set-out são observadas nas Figuras 17b e 17e. A medida em que o período chuvoso se encerra, o NDVI diminui sobre a região, remanescendo altos valores na costa leste do NEB, no norte do estado do MA, nas serras, planaltos e chapadas do semiárido. Na costa leste as ondas de leste e as brisas marítimas e terrestres atuantes nesse período ocasionam precipitações médias mais elevadas (> 200 mm), destoando-se do restante do NEB e coincidindo com os altos valores de NDVI (> 0.6). É observado que apesar de não ocorrer elevada precipitação média no norte do estado do MA, altos valores de NDVI ainda são encontrados; o que é esperado tendo em vista que essa região é configurada em grande parte por uma vegetação de floresta ombrófila (IBGE, 2004b), na qual mantém suas folhas durante todo o ano (vegetação perenifólia). Ademais, apesar de se observar baixa precipitação média sobre a região central do NEB, ainda assim é constatado altos valores de NDVI nas serras, planaltos e chapadas do semiárido. SOUZA & OLIVEIRA (2006) elucidam que essas áreas representam verdadeiras “ilhas verdes”, abrigadas por mesoclimas de altitude que propiciam formações florestais.

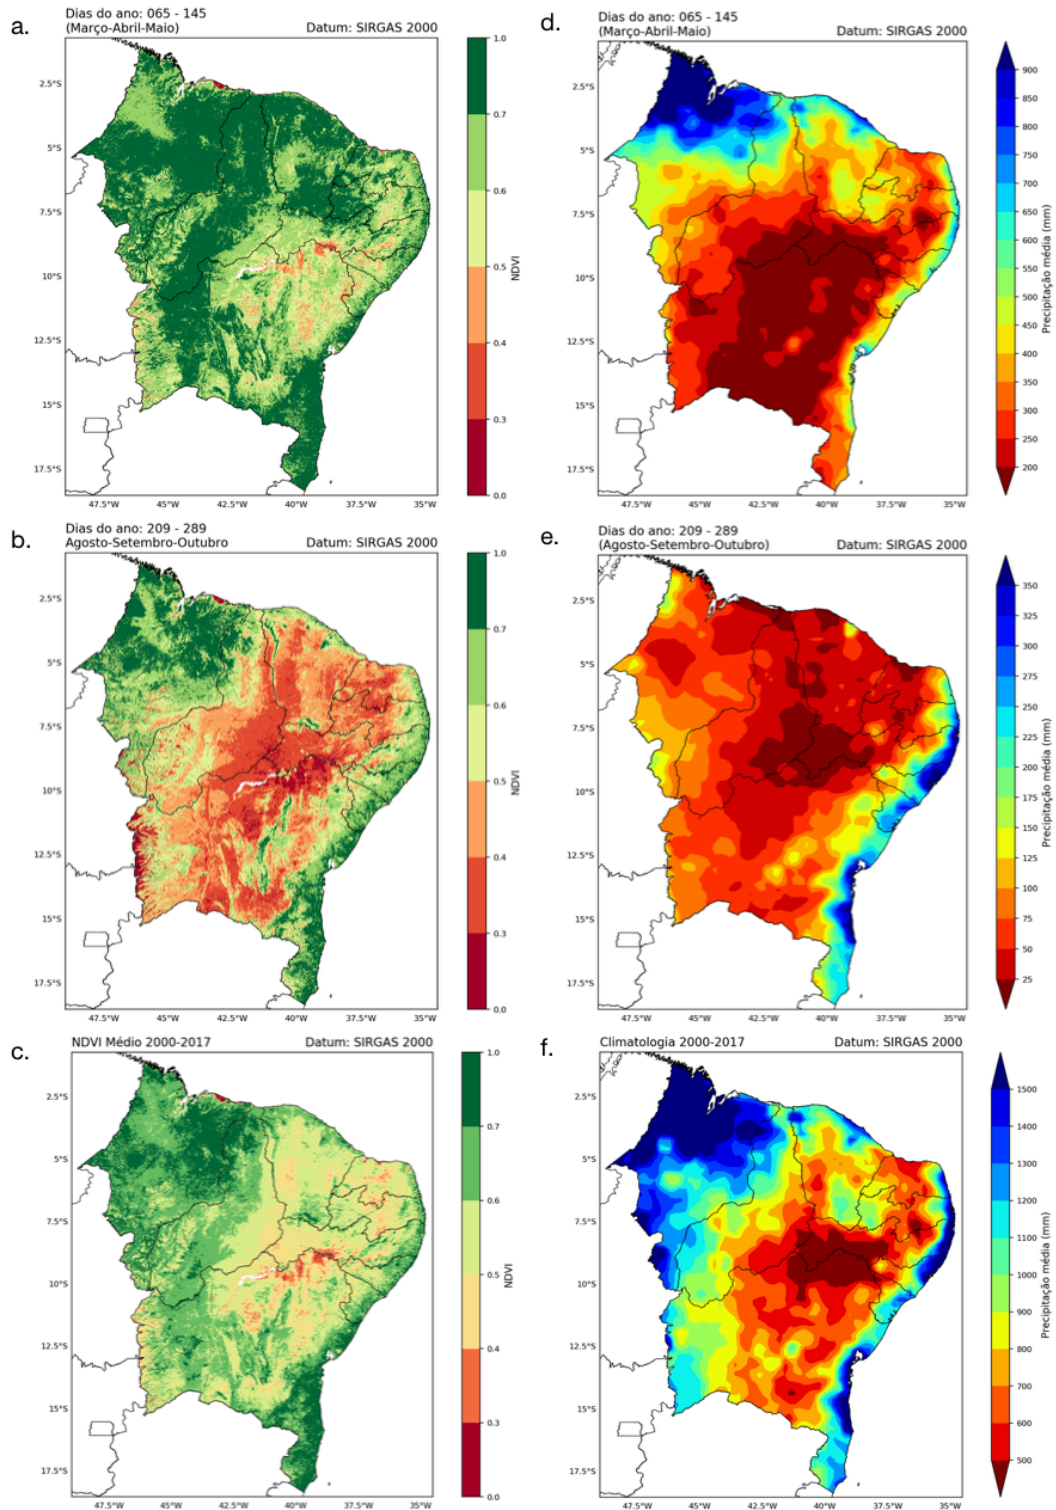
As médias anuais do NDVI e da Precipitação no período 2000 a 2017 são representados nas Figuras 17c e 17f. O NEB é caracterizado por uma média de NDVI de 0.54

quando se considera todo o período (411 imagens). Os padrões espaciais da média anual do NDVI e da precipitação coincidem sobre toda a região; Os menores valores de NDVI (< 0.3) são encontrados na Caatinga em consequência das baixas médias anuais de precipitação. Os valores mais elevados (> 0.7) se apresentam no norte do MA, no sudeste da BA e nos enclaves úmidos do semiárido, mostrando-se relacionados com a ocorrência de chuvas.

Observando as delimitações dos biomas no NEB, os padrões espaciais do NDVI não mostram-se relacionados com o Cerrado e a Amazônia. Entretanto, há similaridade nos biomas Caatinga e Mata Atlântica, convergindo com os resultados encontrados por ERASMI *et al.* (2009), que analisou o período 1982-2006 com o sensor AVHRR, e com SCHUCKNECHT *et al.* (2013) que investigou o período 2001-2006 com o sensor MODIS.

Em Apêndice D são disponibilizadas as figuras das médias do NDVI para cada dia do ano (2000-2017). Esse conjunto de imagens demonstra o comportamento médio da vegetação ao longo do ano, iniciando com feições de baixo NDVI concentradas sobre o nordeste do NEB em janeiro. No pico do período chuvoso, em abril, essas feições passam a se concentrar sobre a parte central do NEB, se expandindo pelo semiárido até “retornarem” a sua posição inicial a partir de outubro.

Figura 17 - Distribuição espacial do NDVI médio e da Precipitação média considerando o período 2000 a 2017. **(a)** NDVI médio dos dias julianos 065-145; **(d)** Precipitação média dos dias julianos 065-145; **(b)** NDVI médio dos dias julianos 209-289; **(e)** Precipitação média dos dias julianos 209-289; **(c)** NDVI médio anual; **(f)** Precipitação média anual.



Fonte: Elaborado pelo autor.

5.3.2.2 Distribuição espacial do coeficiente de variação

A distribuição espacial do CV para o trimestre mar-abr-mai, trimestre ago-set-out e média anual, são apresentados nas Figuras 18a, 18b e 18c, respectivamente.

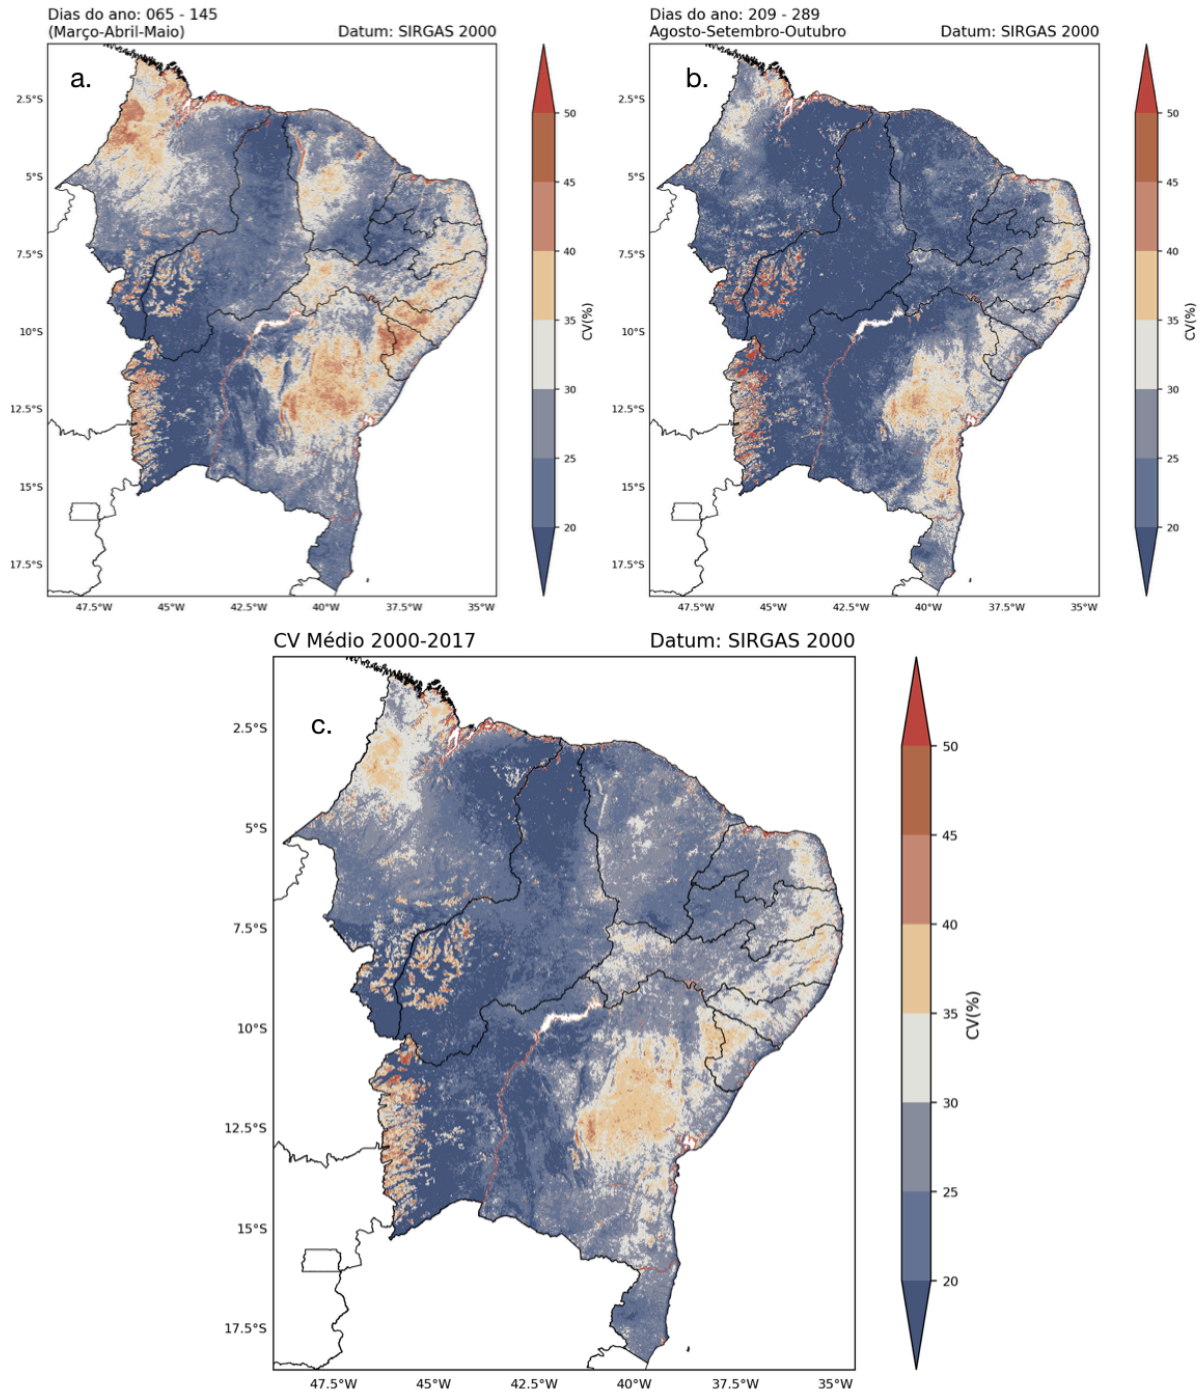
O CV expressa a magnitude da variabilidade interanual do NDVI. Os fatores influentes nessa variabilidade podem estar ligados à sistemas atmosféricos atuantes na região (TUCKER *et al.*, 1991; LU *et al.*, 2015), à processos de degradação do solo (MILICH & WEISS, 2000) e ao desmatamento, fragmentação e heterogeneidade da vegetação (FERREIRA *et al.*, 2007). Ainda, altos valores do CV podem estar relacionados à áreas de maior vulnerabilidade a estresse hídrico (ERASMI *et al.*, 2009) ou podem indicar fitofisionomias com menores quantidades de biomassa estrutural (FERREIRA *et al.*, 2006).

Comparando o CV nas Figuras 18a e 18b, o trimestre mar-abr-mai apresentou maior variabilidade com valor do CV médio regional de 22% enquanto o trimestre ago-set-out manifestou valor médio regional de 18%. Os resultados mostram que 64% da área no trimestre mar-abr-mai tiveram variabilidade menor que 25%, a medida que o trimestre ago-set-out registrou 82% da área. O CV médio anual por sua vez, apresenta média de 22% considerando toda a região, com 68% da área coberta por valores de CV menores que 25% (Figura 18c).

Atentando-se para os resultados encontrados em ERASMI *et al.* (2009) e SCHUCKNECHT *et al.* (2013), os autores verificaram padrões espaciais de CV bem delimitados para os biomas da Caatinga e da Mata Atlântica. Neste trabalho se observa que na maior parte do NEB a distribuição espacial do CV médio anual diverge desses autores, sendo encontrados “*hotspots*” de alta variabilidade sobre a região central da BA, na região costeira leste e na parte ocidental do MA (Figura 18c).

Tendo em vista que não se encontram no NEB níveis de degradação com magnitude equivalente à extensão destes “*hotspots*” e que estes padrões espaciais são muito similares aos das imagens da porcentagem média de *pixels* falhos (Figura 14c), estes altos níveis de variabilidade da vegetação mostram-se relacionados com a nebulosidade. Isso indica que a presença de nuvens nas séries temporais pode superestimam os valores de CV. Nesse caso, seria interessante a investigação de métodos de filtragem de séries temporais (COLDITZ *et al.*, 2008).

Figura 18 - Distribuição espacial do CV no período 2000 a 2017: **(a)** dias julianos 065-145; **(b)** dias julianos 209-289; **(c)** Médias anuais



Fonte: Elaborado pelo autor.

Outro aspecto a ser observado é o contraste entre áreas agrícolas no oeste da BA e no sudeste do PI com áreas adjacentes de baixo CV ($< 30\%$), especialmente durante o período seco (Figura 14b). Essa disparidade pode ser causada por práticas agrícolas adotadas nestas áreas que vão se modificando entre os anos, enquanto a vegetação remanescente se comporta com maior homogeneidade, sendo configurada em maior parte pela sazonalidade da precipitação. Há a possibilidade, portanto, do uso do CV para a delimitação de regiões agrícolas e vegetação remanescente.

6. CONCLUSÕES

Este trabalho buscou analisar a variabilidade espaço-temporal do NDVI no NEB durante o período de 2000 a 2017. Para isso, utilizou-se estatística descritiva nas séries temporais do NDVI para a obtenção dos valores de mínimo, média, máximo, desvio padrão, escore-z e coeficiente de variação. De forma generalista, foram desenvolvidas rotinas computacionais que permitem a aquisição e pré-processamento dos produtos MODIS (NDVI, EVI, Temperatura, entre outros). Através das rotinas, foram automatizadas as etapas de *download* das cenas, a reprojeção, a mosaicagem, o recorte para a região de interesse e a normalização das imagens, apresentando bom desempenho e potencial à auxiliarem no monitoramento operacional da vegetação. Além disso, foi realizada a análise de *pixels* contaminados por nuvens nas imagens a fim verificar a confiabilidade dos dados no espaço e no tempo. Outro objetivo foi a identificação dos padrões espaciais do NDVI e a sua comparação com a precipitação, a delimitação dos biomas e com o relevo.

Para o período de estudo, o NEB apresentou áreas de alta nebulosidade, que incluem parte do MA, as serras úmidas no CE e a costa leste, dificultando a extração de informação confiável sobre a vegetação nessas regiões. Se verificou que 16.3% dos *pixels* de NDVI apresentaram problemas por conta de nuvens, indicando que apesar do algoritmo de composição do produto MOD13Q1 minimizar os efeitos introduzidos pelas nuvens, em certos e períodos e regiões as falhas podem persistir

Com a análise temporal, foram identificados padrões de crescimento e de declínio do NDVI. As curvas média, máxima e mínima apresentaram seus limiares influenciados pela atuação de sistemas de tempo e clima (interação oceano-atmosfera) e, no mesmo sentido, a

curva do CV indicou que chuvas elevam a variabilidade da vegetação no NEB. Ademais, o escore-z (anomalia padronizada) e a média móvel de 3 anos demonstraram uma tendência positiva no período 2000-2011, seguida por uma ruptura no ano de 2012 causada pelo aquecimento anômalo das águas sobre a bacia norte do Oceano Atlântico Tropical, indicativo de dipolo positivo (desfavorável as chuvas no NEB).

A variabilidade da vegetação no NEB mostrou-se elevada tanto no tempo como no espaço. O NDVI médio para todo o período analisado apresentou padrões espaciais similares ao da precipitação média, com maiores valores nas costa leste do NEB, nos enclaves úmidos do semiárido e no norte do MA, refletindo os biomas da Caatinga e da Mata Atlântica. Através do CV médio foram identificados “*hotspots*” de alta variabilidade do NDVI, estando relacionados com a contaminação de nuvens nessas áreas. Com esses problemas os resultados para a curva do CV são menos consistentes. Portanto, a análise do CV tende a ser mais confiável em regiões de poucas falhas. Porém, ainda assim se verifica a potencialidade do CV no realce de regiões agrícolas com áreas de vegetação adjacentes.

Cabe ressaltar a necessidade de testes estatísticos a fim de quantificar a relação espaço-temporal entre a dinâmica da vegetação e a precipitação, tendo em vista que neste trabalho a análise foi realizada de forma visual baseando-se nas figuras do NDVI e da precipitação média. Com isso, seria possível verificar no espaço e no tempo o “*lag*” da resposta da vegetação aos eventos de chuva (TAN *et al.*, 2001).

Ademais, se recomenda a análise de *pixels* defeituosos ao analisar a variabilidade do NDVI no NEB, sobretudo nas áreas mais problemáticas. Embora não se tenha explorado técnicas de separação de *pixels* bons neste trabalho, a análise abre caminho para o emprego de métodos de filtragem de dados em trabalhos futuros, possibilitando assim uma maior confiabilidade dos resultados.

Por fim, demonstra-se que o estudo da variabilidade do NDVI a partir de sensoriamento remoto pode levar à um melhor entendimento do comportamento espaço-temporal da vegetação, sendo possível aplicar a metodologia em estudos mais localizados, uma vez que a resolução espacial do produto MOD13Q1 é de 250m. Trabalhos futuros podem caminhar em direção ao uso de métodos como a análise de componentes principais, redes neurais e *fourier*, bem como o uso de outros índices de vegetação, voltados à identificação de padrões espaço-temporais.

REFERÊNCIAS

- ANDERSON, L. O.; ARAGÃO, L. E. O. C.; LIMA, A. D.; SHIMABUKURO, Y. E. Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados multitemporais do sensor MODIS/TERRA no estado do Mato Grosso, Amazônia brasileira. **Acta Amazonica**, 35 (4), 445-456, 2005.
- ANTUNES, R. L. S. **Variação espaço-temporal de NDVI em área de aproveitamento hidroelétrico - Uhe Santo Antônio, Porto Velho (RO)**. 122 f. Dissertação (Mestrado) - Instituto de Geociências. Programa de Pós-Graduação em Geografia, Universidade Federal do Rio Grande do Sul. Porto Alegre, RS - BR, 2012.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES, G.; LEONARDO, J.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, 22(6), 711-728, 2013.
- BARBOSA, H. A. **Análise espaço temporal de índice de vegetação AVHRR/NOAA e precipitação na região nordeste do Brasil, em 1982-85**. 164 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999
- BARBOSA, H. A; HUETE, A. R.; BAETHGEN, W. E. A 20-year study of NDVI variability over the Northeast Region of Brazil. **Journal of Arid Environments**, 67(2), 288-307, 2006.
- COLDITZ, R.R.; CONRAD, C.; WERHMANN, T.; SCHMIDT, M.; DECH, S. TiSeG: A Flexible Software Tool for Time-Series Generation of MODIS Data Utilizing the Quality Assessment Science Data set. **IEEE Transactions on Geoscience and Remote Sensing**. 46(10), 3296-3308. 2008
- DIDAN, K; MUNOZ, A. B; SOLANO, R.; HUETE, A. **MODIS vegetation index user's guide (MOD13 Series)**. University of Arizona, 2015.

DOURADO, C. D. S. **Áreas de risco de desertificação: cenários atuais e futuros, frente às mudanças climáticas**. 141 f. Tese (Doutorado em Engenharia Agrícola) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, 2017.

ERASMI, S.; MAURER F., PETTA R.A., GEROLD G., BARBOSA, M.P. Inter-annual variability of the Normalized Difference Vegetation Index over Northeast Brazil and its relation to rainfall and El Niño Southern Oscillation. **Geo-Öko**, 30, 185-206, 2009.

FENSHOLT, R.; HORION, S.; TAGESSON, T.; EHAMMER, A.; GROGAN, K.; TIAN, F.; HUBER, S.; VERBESSELT, J.; PRINCE, S. D.; TUCKER, C. J.; RASMUSSEN, K. (2015). Assessment of vegetation trends in drylands from time series of earth observation data. In: **Remote Sensing Time Series** (pp. 159-182). Springer, Cham. 2015.

FERREIRA, A. G.; DA SILVA MELLO, N. G. Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região. **Revista Brasileira de Climatologia**, 1(1), 2005.

FERREIRA, M. E.; FERREIRA, L. G.; HUETE, A. R.; PECCININI, A. A. Análise comparativa dos produtos MODIS Ecologia para o monitoramento biofísico ambiental do bioma cerrado. **Revista Brasileira de Geofísica**, 24(2), 251-260, 2006.

FERREIRA, M. E.; FERREIRA JR, L. G.; FERREIRA, N. C.; ROCHA, G. F.; NEMAYER, M. (2007). Desmatamentos no bioma Cerrado: uma análise temporal (2001-2005) com base nos dados MODIS-MOD13Q1. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 13, 3877-3883, 2007

HASTENRATH, S.; HELLER, L. Dynamics of climatic hazards in northeast Brazil. **Quarterly Journal of the Royal Meteorological Society**, 103(435), 77-92, 1977.

HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, 7 (11), 1417-1434, 1986.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote sensing of environment**, 83(1-2), 195-213, 2002.

IBGE, Instituto Brasileiro de Geografia e Estatística - Mapa de biomas do Brasil. 2004a

IBGE, Instituto Brasileiro de Geografia e Estatística - Mapa de vegetação do Brasil. 2004b

JACKSON, T. J.; CHEN, D.; COSH, M.; LI, F.; ANDERSON, M.; WALTHALL, C.; DORIASWAMY, P.; HUNT, E. R. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. **Remote Sensing of Environment**, 92(4), 475-482, 2004.

JENSEN, J. R.; SAALFELD, A.; BROOME, F.; COWEN, D.; PRICE, K.; RAMSEY, D.; LAPINE, L.; USERY, E. L. Chapter 2: Spatial Data Acquisition and Integration. In: R. B. MCMASTER, R.B.; USERY, E. L. (Eds.). **A Research Agenda for Geographic Information Science**, Boca Raton: CRC Press, 17–60, 2005.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective 2/e**. Pearson Education India, 2009.

JIANBO, W.; JIANJUN, B.; LELE, L.; YUAN, Y. Vegetation supply water index based on MODIS data Analysis of the in Yunnan in spring of 2012. In: Agro-geoinformatics (Agro-geoinformatics 2014), **Third International Conference on IEEE**, 1-7, 2014

KANE, R. P. Prediction of droughts in north–east Brazil: Role of ENSO and use of periodicities. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, 17(6), 655-665, 1997.

KAYANO, M. T.; ANDREOLI, R. V. Variabilidade Decenal a Multidecenal. In: CAVALCANTI, I. F. A. **Tempo e Clima no Brasil**. São Paulo, Oficina de Textos, p. 373-383, 2009.

KOUSKY, V. E. Frontal influences on northeast Brazil. **Monthly Weather Review**, 107(9), 1140-1153, 1979.

LAWHEAD, J. **Learning geospatial analysis with python**. Birmingham – Mumbai: Packt Publishing, 2015.

LEIVAS, J. F.; ANDRADE, R. G.; VICTORIA, D. D. C.; TORRESAN, F. E.; BOLFE, E. L. Monitoramento da seca 2011/2012 no nordeste brasileiro a partir do satélite SPOT-VEGETATION e TRMM. **Revista Engenharia na Agricultura**, 22 (3), 211-221, 2014.

LILLESAND, T. M.; KIEFER, R.W. **Remote Sensing and Image Processing**. New York: J. Wiley. 1987.

LIU, W. T.; NEGRÓN JUÁREZ, R. I. ENSO drought onset prediction in northeast Brazil using NDVI. **International Journal of Remote Sensing**, 22 (17), 3483-3501, 2001.

LOPES, D. C. **Análise de imagens de séries temporais NDVI do sensor MODIS no Parque Nacional da Serra da Canastra**. Monografia. 27 f. Departamento de Geografia – Universidade de Brasília, 2015.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. São Paulo: Blucher, 2015.

LU, L.; KUENZER, C.; WANG, C.; GUO, H.; LI, Q. Evaluation of three MODIS-derived vegetation index time series for dryland vegetation dynamics monitoring. **Remote Sensing**, 7(6), 7597-7614, 2015.

LYON, J. G.; YUAN, D.; LUNETTA, R. S.; ELVIDGE, C. D. A change detection experiment using vegetation indices. **Photogrammetric engineering and remote sensing**, 64(2), 143-150, 1998.

MADDEN, R.; JULIAN, P.R. Description of global scale circulation cells in the tropics with a 40-50 day period. **Journal of the Atmospheric Sciences**, 29, 1109-1123, 1972.

MARENGO, J. A.; ALVES, L. M.; BESERRA, E. A.; LACERDA, F. F. (2011). Variabilidade e mudanças climáticas no semiárido brasileiro. In: INSTITUTO NACIONAL DO SEMI-ÁRIDO. **Recursos hídricos em regiões áridas e semiáridas**. 384-422, 2011.

MARENGO, J. A.; CUNHA, A. P.; ALVES, L. M. A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico. **Climanálise**, 3, 49-54, 2016.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R.; CUNHA, A. P.; BRITO, S.; MORAES, O. L. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. In: **Anais da Academia Brasileira de Ciências**, 90(2), 1973-1985, 2018.

MEDEIROS, S. D. S.; CECÍLIO, R. A.; DE MELO JÚNIOR, J. C.; DA SILVA JUNIOR, J. L. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas na Região Nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, 9(2), 247-255, 2005.

MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. Oficina de textos, 2017.

MILICH, L.; WEISS, E. GAC NDVI interannual coefficient of variation (CoV) images: Ground truth sampling of the Sahel along north-south transects. **International Journal of Remote Sensing**, 21 (2), 235-260, 2000.

MIN, Ministério da Integração Nacional. **Mapeamento dos espelhos d'água do Brasil**. Ceará, 2008.

MORAES, R., A.; ROCHA, J. V. Imagens de coeficiente de qualidade (Quality) e de confiabilidade (reliability) para seleção de pixels em imagens de NDVI do sensor MODIS para monitoramento da cana-de-açúcar no estado de São Paulo. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto**. Curitiba - PR. 2011.

MORELLATO, L.P.C.; HADDAD C.F.B. Introduction: The Brazilian Atlantic Forest. **Biotropica**, 32, 786-792, 2000.

NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America. **Journal of climate**, 9(10), 2464-2479, 1996.

NOBRE, P. As origens das águas no Nordeste. In: AGÊNCIA NACIONAL DAS ÁGUAS. **A questão da água no nordeste**. Brasília, DF, 2012.

NOVAS, M. F. B.; CRUZ, P. P. N.; SILVA, R.; DI PACE, F. T. Análise da variação dos índices de vegetação estimados por sensoriamento remoto em dois períodos ao sul da bacia do rio Traipu-AL. In: **II Simpósio Brasileiro de Ciências e Tecnologia da Geoinformação**. Recife - PE, 2008.

OLIVEIRA, J.C. **Janela de regressão: uma análise espacial e temporal para estimar valores de NDVI classificados com baixa qualidade em séries temporais MODI**. 119 f. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

PETERS, A. J.; WALTER-SHEA, E. A.; JI, L.; VINA, A.; HAYES, M.; SVOBODA, M. D. Drought monitoring with NDVI-based standardized vegetation index. **Photogrammetric engineering and remote sensing**, 68(1), 71-75, 2002.

PEZZI, L. P.; CAVALCANTI, I. F. A. The relative importance of ENSO and tropical Atlantic sea surface temperature anomalies for seasonal precipitation over South America: a numerical study. **Climate Dynamics**, 17(2-3), 205-212, 2001.

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

RÊGO, V. C. **Geoprocessamento para análises agrícolas utilizando a linguagem Python: estudo de caso no perímetro de irrigação Baixio do Irecê**. 103 f. Dissertação (Mestrado em Ciências e Sistemas de Informação Geográfica) - Instituto Superior de Estatística e Gestão de Informação, Universidade Nova de Lisboa, 2017.

RIBEIRO, C. A. D.; PAIVA, Y. G.; FERREIRA, D. S.; XAVIER, A. C. Banco de dados temporal de imagens NDVI do sensor MODIS para o Espírito Santo: **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**. 2007.

RODRIGUES, C. P. **Estudo do fluxo de carbono utilizando geotecnologias**. 93 f. Dissertação (Mestrado em Sensoriamento Remoto) - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal Do Rio Grande Do Sul, 2010.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. In: **Third Earth Resources Technology Satellite-1 Symposium**, Greenbelt: NASA SP-351, 3010–3017, 1974.

SCHUCKNECHT, A.; ERASMI, S.; NIEMEYER, I.; MATSCHULLAT, J. (2013). Assessing vegetation variability and trends in north-eastern Brazil using AVHRR and MODIS NDVI time series. **European Journal of Remote Sensing**, 46(1), 40-59, 2013.

NOGUEIRA DE SOUZA, M. J.; PINTO VIDAL DE OLIVEIRA, V. Os enclaves úmidos e sub-úmidos do semi-árido do Nordeste brasileiro. **Mercator-Revista de Geografia da UFC**, 5(9), 2006.

SILVA, L. F. **Precipitação do norte do nordeste brasileiro e padrões de temperatura da superfície e pressão ao nível do mar: relações com as fases do el niño/oscilação sul e oscilação decadal do pacífico**. 95 f. Dissertação (Mestrado do Curso de Pós-Graduação em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

SINGH, R. P.; ROY, S.; KOGAN, F. (2003). Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India. **International Journal of Remote Sensing**, 24(22), 4393-4402, 2003.

TAN, P.; STEINBACH, M.; KUMAR, V.; POTTER, C.; KLOOSTER, S.; TORREGROSA, A. Finding spatio-temporal patterns in earth science data. In: **KDD 2001 Workshop on Temporal Data Mining** (Vol. 19), 2001.

TUCKER, C. J.; NEWCOMB, W. W.; LOS, S. O.; PRINCE, S. D. Mean and inter-year variation of growing-season normalized difference vegetation index for the Sahel 1981-1989. **International Journal of Remote Sensing**, 12(6), 1133-1135, 1991.

UVO, C. R. B. **A Zona de Convergência Intertropical (ZCIT) e sua relação com a precipitação da Região Norte do Nordeste Brasileiro**. 92 f. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1989.

UVO, C.; BERNDTSSON, R. Regionalization and spatial properties of Ceará State rainfall in northeast Brazil. **Journal of Geophysical Research: Atmospheres**, 101(D2), 4221-4233, 1996.

VIEIRA, R. M. D. S. P.; CUNHA, A. P. M. D. A.; ALVALÁ, R. C. D. S.; CARVALHO, V. C.; FERRAZ NETO, S.; SESTINI, M. F. Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. **Revista Brasileira de Meteorologia**, 28(2), 129-138, 2013.

YENGOH, G. T.; DENT, D.; OLSSON, L.; TENGBERG, A. E.; TUCKER III, C. J. **Use of the Normalized Difference Vegetation Index (NDVI) to Assess Land Degradation at Multiple Scales: Current Status, Future Trends, and Practical Considerations**. Springer Briefs in Environmental Science, 2015.

APÊNDICE A - ROTINA DE AQUISIÇÃO DOS DADOS MODIS

```
##### -*- coding: utf-8 -*- #####  
"""  
Created on Tue May 15 13:24:05 2018  
  
@author: Diego Xavier  
  
server: https://e4ftl01.cr.usgs.gov/MOLT/  
find data: https://ladsweb.modaps.eosdis.nasa.gov/search/  
"""  
  
import os, glob  
from pymodis import downmodis  
from datetime import datetime  
  
startTime = datetime.now()  
#####  
  
# Years to be downloaded  
minimum = 2000  
maximum = 2017  
  
for i in range(10):  
    try:  
        for year in range(minimum, maximum+1):  
            print('Downloading %s files ...' % (str(year)))  
            # destination folder  
            if not os.path.exists(r'D:\ndvi.old\speed_test\MOD13A3\%s' %  
(str(year))):  
                os.mkdir(r'D:\ndvi.old\speed_test\MOD13A3\%s' % (str(year)))  
            dest = r'D:\ndvi.old\speed_test\MOD13A3\%s' % (str(year))  
            # credentials (registration on: https://urs.earthdata.nasa.gov/  
users/new)  
            user = 'user'  
            password = 'password'  
            # tiles and product to download  
            tiles = 'h13v09,h13v10,h14v09,h14v10'  
            product = 'MOD13A3.006'  
            # starting day  
            day = '%s-01-01' % str(year)  
            enddate = '%s-12-31' % str(year)  
            # number of day to download  
            delta = 1
```

```
        modisDown = downmodis.downModis(destinationFolder=dest,
password=password, user=user, tiles=tiles, product=product, today=day,
enddate=enddate, delta=delta)

        modisDown.connect()
        modisDown.downloadsAllDay()

        print(datetime.now() - startTime)
        print(glob.glob('D:\ndvi.old\speed_test\MOD13A3\*\*.hdf'))

        print(datetime.now() - startTime)

    except AttributeError:
        print 'Retrying ...'
        continue
    else:
        break
else:
    print 'network is down, act accordingly'
```

APÊNDICE B - ROTINA DE PRÉ-PROCESSAMENTO

```
##### -*- coding: utf-8 -*- #####  
"""
```

Created on Thu May 31 10:46:17 2018

@author: Diego Xavier

GDALwarp help on <http://www.gdal.org/gdalwarp.html>

Based on examples on:

[https://gis.stackexchange.com/questions/42584/how-to-call-gdal-translate-from-python-code?](https://gis.stackexchange.com/questions/42584/how-to-call-gdal-translate-from-python-code?utm_medium=organic&utm_source=google_rich_qa&utm_campaign=google_rich_qa)

<http://geoexamples.blogspot.com/2012/12/raster-calculations-with-gdal-and-numpy.html>

<http://geoexamples.blogspot.com/2012/12/raster-calculations-with-gdal-and-numpy.html>

```
"""
```

```
# Import modules
```

```
import numpy as np
```

```
import os, subprocess
```

```
from os import path as osp
```

```
from glob import glob as glb
```

```
from osgeo import gdal
```

```
from osgeo.gdalnumeric import *
```

```
from osgeo.gdalconst import *
```

```
from pymodis.convertmodis_gdal import convertModisGDAL
```

```
from datetime import datetime
```

```
startTime = datetime.now()
```

```
# Input
```

```
minimum = 2000
```

```
maximum = 2017
```

```
product = "MOD13Q1"
```

```
folder = r"D:\ndvi.old\speed_test\MOD13Q1"
```

```
shape = r"D:\ndvi.old\speed_test\shp"
```

```
def preprocess(minimum, maximum, product, folder, shape, epsg=4326, mode='ndvi',  
of='nc', rmv=True, meta=True):
```

```
    """
```

```
    - Este script reprojeta, junta as cenas, recorta para o shapefile,  
    normalisa e transforma para NETCDF os dados do sensor MODIS/TERRA.
```

```
    - Os dados originais .hdf devem estar contidos em pastas nomeadas com o  
    respectivo ano da imagem.
```

```
    minimum: ano inicial (int)
```

```

maximum: ano final (int)
product: nome do produto modis (ex: MOD13Q1) (str)
folder: caminho da pasta com os dados baixados, organizada em sub-pastas
por ano (str)
shape: caminho do arquivo shapefile para o recorte (str)
epsg: codigo epsg para a reprojecao da imagem. Padrao como WGS84 (int)
mode: banda a ser processada. Para qualidade, inserir 'qa' (str).
Temperatura inserir 'temp'.
of: formato final do arquivo. 'nc' para NETCDF, 'tif' para GeoTIFF e
'both' para gerar ambos (str)
rmv: remove os arquivos gerados durante o processo (bool)
meta: transferencia dos metadados originais (bool)

return: tempo total do processamento
"""

```

```

#####
#####

```

```

# REPROJECT #

```

```

for year in range(minimum, maximum+1):
    print year
    inFile = '%s.A%s*.hdf' % (product, year)
    path = r'%s%s' % (folder, year)
    fls = sorted(glob(osp.join(path, inFile)))
    print len(fls), 'files'
    if len(fls) % 4 == 0:
        print('OK')
    else:
        print('Files not divisible by 4: files not downloaded correctly')

# Create or check mode folder
if osp.isdir(r'%s%s%s' % (folder, year, mode)) == False:
    os.mkdir(r'%s%s%s' % (folder, year, mode))
    path = r'%s%s%s' % (folder, year, mode)
else:
    path = r'%s%s%s' % (folder, year, mode)

# Layer selection
if mode == 'ndvi':
    subset = [1,0,0,0,0,0,0,0,0,0,0,0]
    band = 'NDVI'
if mode == 'qa':
    subset = [0,0,0,0,0,0,0,0,0,0,0,1]
    band = 'reliability' # check qa
if mode == 'temp':
    subset = [1,0,0,0,0,0,0,0,0,0,0,0]
    band = 'km'

```

```

# Reprojecting files
fls_rpjct = sorted(glb(osp.join(path, '%s.A*mosaic.hdf' % product)))

for f in fls:
    # Check if file exists
    prefix = r'%s\s.rpjct.tif' % (path, osp.basename(f)[:4])

    if osp.isfile(prefix):
        print('%s exists' % (prefix))
    else:
        proj = convertModisGDAL(f, prefix, subset, res=None,
outformat='GTiff', epsg=epsg)
        proj.run()
    # rename
    fname = glb('%s\*%s.tif' % (path, band))
    os.rename(fname[0], prefix)
    print('file renamed...')
    print (' ')

print(datetime.now() - startTime)

#####
#####

# MERGE AND METADATA #

for year in range(minimum, maximum+1):
    print year
    # mode folder
    if osp.isdir(r'%s\s\s\s' % (folder, year, mode)) == False:
        os.mkdir(r'%s\s\s\s' % (folder, year, mode))
        path = r'%s\s\s\s' % (folder, year, mode)
    else:
        path = r'%s\s\s\s' % (folder, year, mode)

    fls_rpjct = sorted(glb(osp.join(path, '%s.A*.tif' % product)))
    print fls_rpjct
    # Getting day of year list
    days = []
    for f in fls_rpjct:
        days.append(osp.basename(f).split('.', 7)[1][:-3:])
    days = np.unique(days)

    # Check if file exists
    prefix = r'%s\s.006.mosaic.tif' % (path, osp.basename(f)[:16])

    if osp.isfile(prefix):
        print('%s exists' % (prefix))

```

```

else:
    os.chdir(path)
    for i, ddd in enumerate(days):
        destName = product+".A"+str(year)+ddd+".006.mosaic.vrt"
        srcDSTab = glb(path+"\\"+product+".A"+str(year)+ddd+"*.tif")

        # Creating VRTs
        #if i == 0:
        print 'Creating VRT...'
        gdal.BuildVRT(destName, srcDSTab)
        # Translating VRTs to GeoTiff
        translateCmd = 'gdal_translate -of GTiff %s\\%s %s\\%s.tif' %
(path, destName, path, destName[0:-4])
        sub = subprocess.Popen(translateCmd)
        sub.wait()
        print 'Merging ...', '%s\\%s.tif' % (path, destName[0:-4])

    # Transfer Metadata
    if meta:
        fls_msc = sorted(glb(osp.join(path, '%s.A*mosaic.tif' %
product)))
        k = 0
        for fl in fls_msc:
            print 'Getting metadata %s' % (fls_rpjct[0+k])
            print 'into -> %s' % (fl)
            print ' '
            ds_in=gdal.Open(fls_rpjct[0+k])
            ds_out=gdal.Open(fl)
            md = ds_in.GetMetadata()
            ds_out.SetMetadata(md)
            ds_in=None
            ds_out=None
            k += 4

    # Removing fls
    if rmv:
        print 'removing rpjct and vrt files...'
        f1 = glb(osp.join(path, '*rpjct.tif'))
        f2 = glb(osp.join(path, '*.vrt'))
        for f in f1+f2:
            os.remove(f)

print(datetime.now() - startTime)

```

```

#####
#####

```

```

# CLIP TO SHAPEFILE #

```

```

print 'Clip years:', range(minimum, maximum+1)

for year in range(minimum, maximum+1):
    print year
    inFile = '%s.A%s*.006.mosaic.tif' % (product, str(year))
    dest = r'%s\\%s\\%s' % (folder, str(year), mode)
    fls = sorted(glb(osp.join(dest, inFile)))
    print len(fls)

    for f in fls:

        # Check if file exists
        prefix = r'%s\\%s.006.mosaic.clip.tif' % (dest, osp.basename(f)[:16])

        if osp.isfile(prefix):
            print('%s exists' % (prefix))
        else:
            raster = f
            ddd = str(osp.basename(f).split('.', 7)[1][-3:])
            outFile = osp.join(dest, '%s.A%s%s.006.mosaic.clip.tif' %
(product, year, ddd))

            # Check if file exists and remove it
            my_file = r'%s\\%s\\%s\\%s.A%s%s.006.mosaic.clip.tif' % (product,
folder, mode, str(year), str(year), ddd)
            chk_file = osp.exists(my_file)
            if chk_file:
                print 'Removing file ...'
                os.remove(my_file)

            warpCmd = 'gdalwarp -dstnodata -3000 -cutline %s %s %s -
crop_to_cutline -overwrite' % (shape, raster, outFile)
            sub = subprocess.Popen(warpCmd)
            sub.wait()
            print 'Clipping', outFile

    # Removing fls
    if rmv:
        print 'removing mosaic files...'
        fl = glb(osp.join(dest, '*mosaic.tif'))
        for f in fl:
            os.remove(f)

print(datetime.now() - startTime)

#####
#####
# NORMALISATION #

```

```

if mode == 'ndvi': # check qa
    print 'Calculate years:', range(minimum, maximum+1)

for year in range(minimum, maximum+1):
    print year
    inFile = '%s.A%s*.006.mosaic.clip.tif' % (product, str(year))
    dest = r'%s\%s\%s' % (folder, str(year), mode)
    fls = sorted(glob(osp.join(dest, inFile)))
    print len(fls)

for f in fls:
    # Check if file already exists
    prefix = r'%s\%s.006.tif' % (dest, osp.basename(f)[:16])

    if osp.isfile(prefix):
        print('%s exists' % (prefix))
    else:
        # Open the dataset
        ds1 = gdal.Open(f, GA_ReadOnly )
        band1 = ds1.GetRasterBand(1)
        # Read the data into numpy arrays
        data1 = BandReadAsArray(band1)
        # The actual calculation
        dataOut = np.multiply(data1, 0.0001)
        # Write the out file
        driver = gdal.GetDriverByName("GTiff")
        ddd = str(osp.basename(f).split('.', 7)[1][-3:])
        outFile = osp.join(dest, '%s.A%s%s.006.tif' % (product,
year, ddd))
        dsOut = driver.Create(outFile, ds1.RasterXSize,
ds1.RasterYSize, 1, GDT_Float32)
        CopyDatasetInfo(ds1,dsOut)

        bandOut=dsOut.GetRasterBand(1)
        BandWriteArray(bandOut, dataOut)
        print 'Calculating', outFile
        # Close the datasets
        band1 = None
        ds1 = None
        bandOut = None
        dsOut = None
        outFile = None

# Removing fls
if rmv:
    print 'removing clip and xml files...'

```



```

        f1 = glob(osp.join(dest, '*mosaic.clip.tif'))
        f2 = glob(osp.join(dest, '*.xml'))
        for f in f1+f2:
            os.remove(f)

    print(datetime.now() - startTime)

#####
#####
# CONVERT TO NETCDF #
if of == 'nc' or of == 'both':
    fls = sorted(glob(r'%s\*\%s\*.tif' % (folder, mode))) #check qa

    for f in fls:

        inFile = f
        outFile = osp.join(osp.dirname(f), osp.basename(f)[: -4] + '.nc')
        if osp.isfile(outFile):
            print '%s exists...' % outFile
            continue
        else:
            transCmd = "gdal_translate -of NetCDF {0} {1}".format(inFile,
outFile)
            sub = subprocess.Popen(transCmd)
            sub.wait()
            #print transCmd
            print 'input: ', inFile
            print 'output:', outFile
            print ' '

# Removing fls
if of == 'nc':
    print 'removing tif files...'
    for f in fls:
        os.remove(f)


    print(datetime.now() - startTime)
    return datetime.now() - startTime
else:
    print(datetime.now() - startTime)
    return datetime.now() - startTime

preprocess(minimum, maximum, product, folder, shape, of='nc', mode='ndvi')

```

APÊNDICE C - FIGURAS DOS PIXELS FALHOS


Dia do ano: 001
01/Jan a 16/Jan (2001-2017) Datum: SIRGAS 2000



100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)


Dia do ano: 017
17/Jan a 01/Fev (2001-2017) Datum: SIRGAS 2000



100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)


Dia do ano: 033
02/Fev a 17/Fev (2001-2017) Datum: SIRGAS 2000



100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)

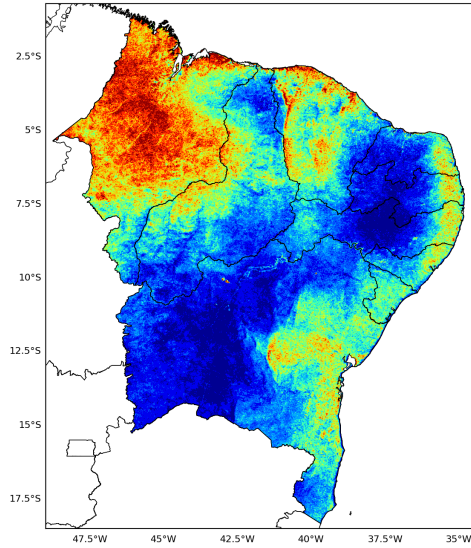
Dia do ano: 049
18/Fev a 04/Mar (2000-2017) Datum: SIRGAS 2000



100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)


Dia do ano: 065
05/Mar a 20/Mar (2000-2017) Datum: SIRGAS 2000



100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)

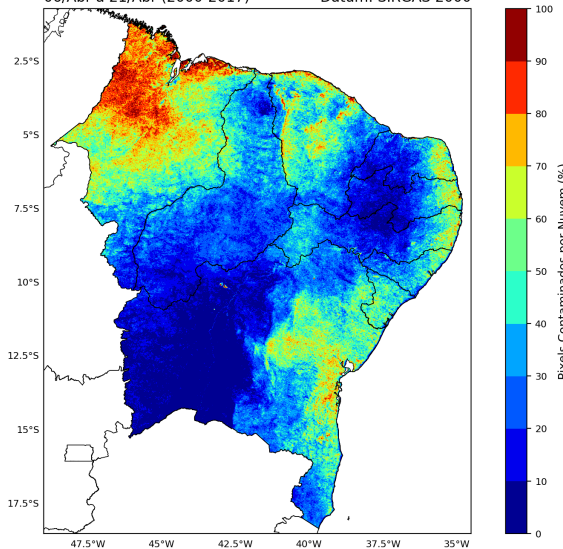
Dia do ano: 081
21/Mar a 05/Abr (2000-2017) Datum: SIRGAS 2000




100
90
80
70
60
50
40
30
20
10
0

Pixels Contaminados por Nuvem (%)

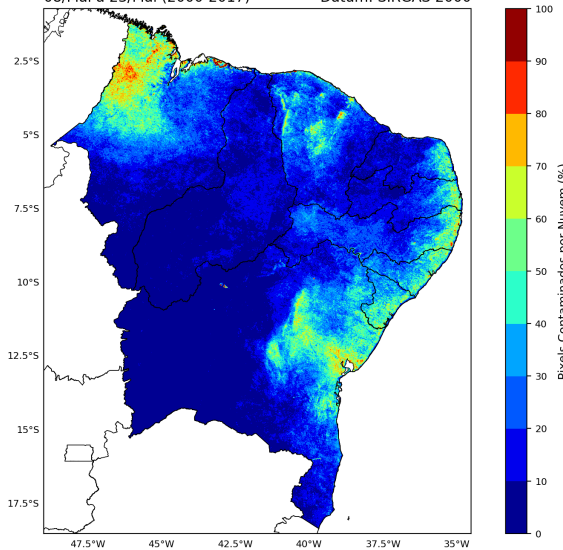
Dia do ano: 097
06/Abr a 21/Abr (2000-2017) Datum: SIRGAS 2000



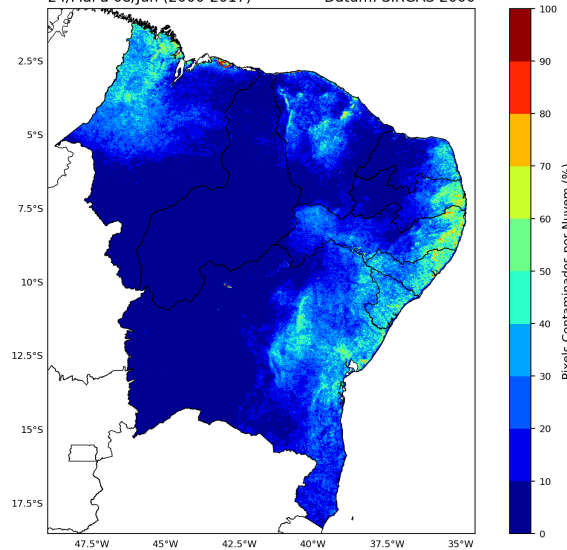
Dia do ano: 113
22/Abr a 07/Mai (2000-2017) Datum: SIRGAS 2000



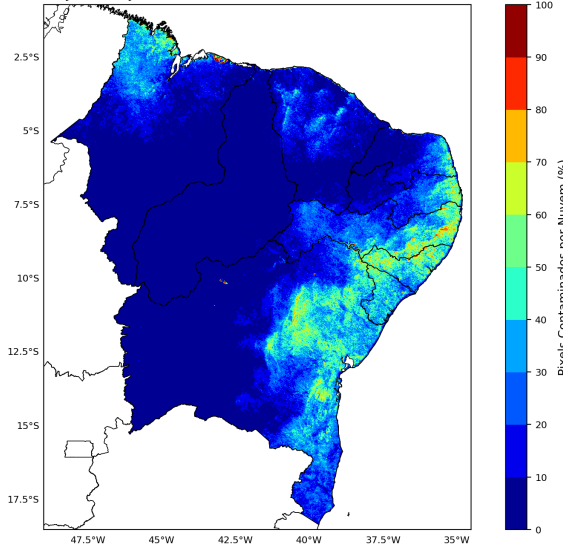
Dia do ano: 129
08/Mai a 23/Mai (2000-2017) Datum: SIRGAS 2000



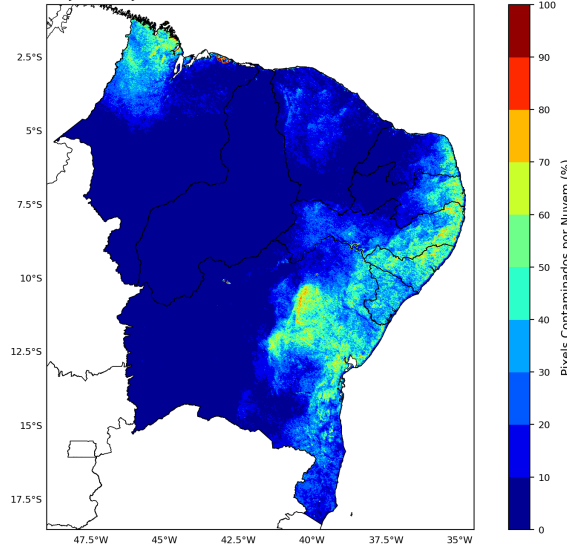
Dia do ano: 145
24/Mai a 08/Jun (2000-2017) Datum: SIRGAS 2000




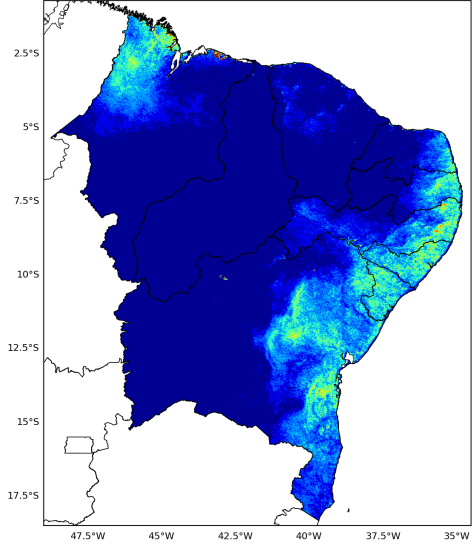
Dia do ano: 161
09/Jun a 24/Jun (2000-2017) Datum: SIRGAS 2000




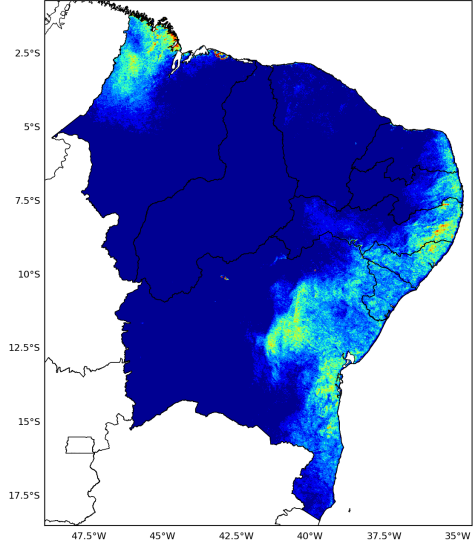
Dia do ano: 177
25/Jun a 10/Jul (2000-2017) Datum: SIRGAS 2000




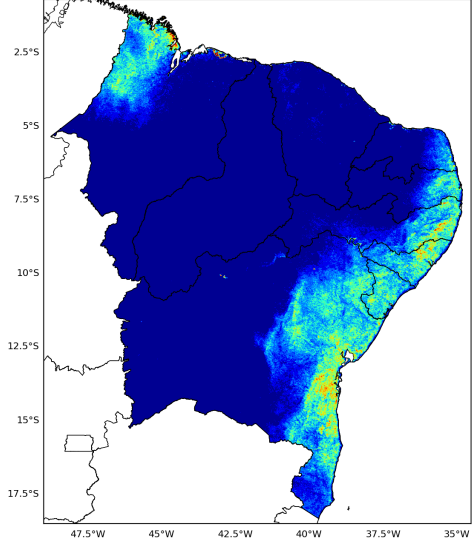
Dia do ano: 193
11/Jul a 26/Jul (2000-2017) Datum: SIRGAS 2000




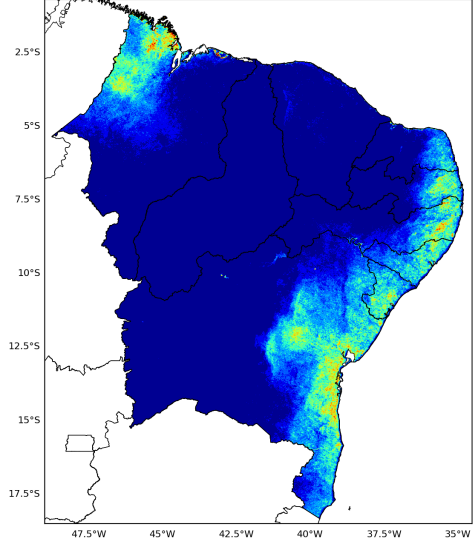
Dia do ano: 209
27/Jul a 11/Ago (2000-2017) Datum: SIRGAS 2000




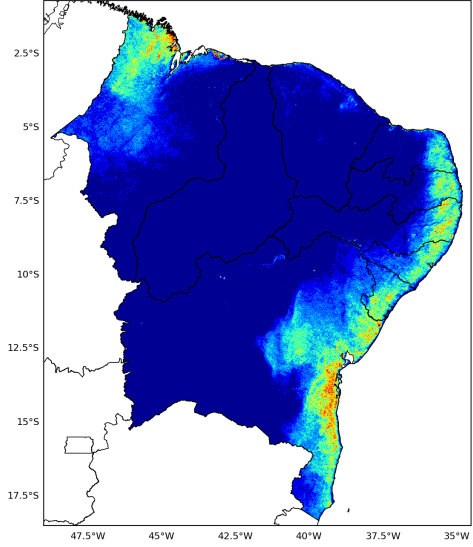
Dia do ano: 225
12/Ago a 27/Ago (2000-2017) Datum: SIRGAS 2000




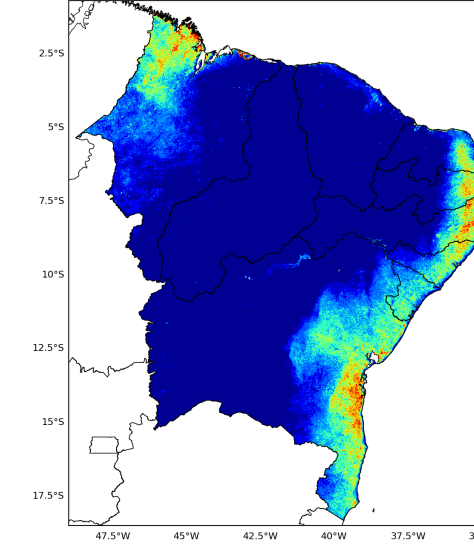
Dia do ano: 241
28/Ago a 12/Set (2000-2017) Datum: SIRGAS 2000

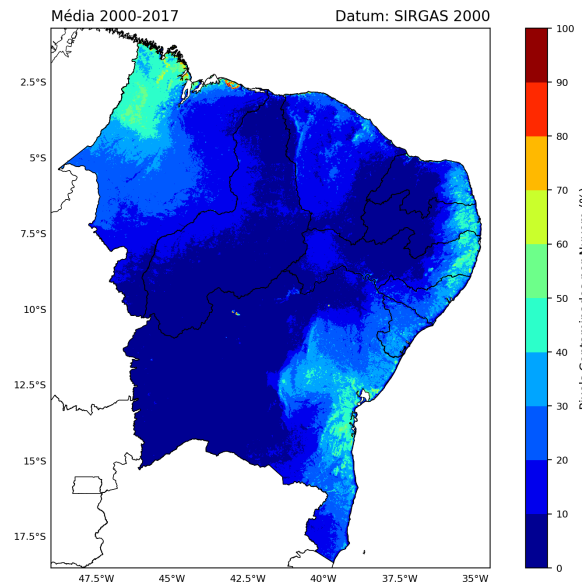
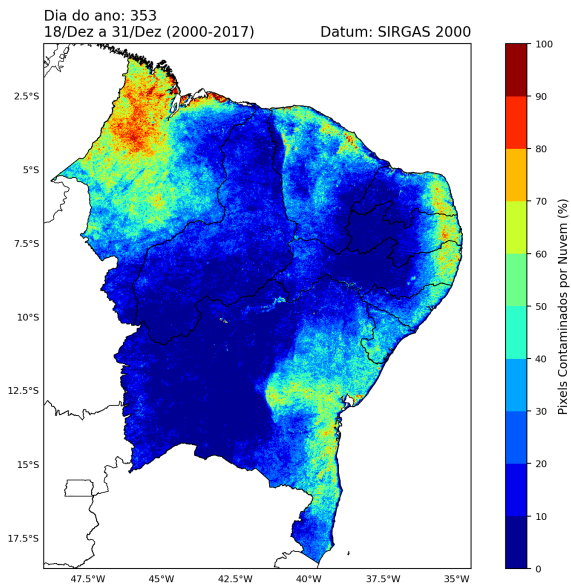
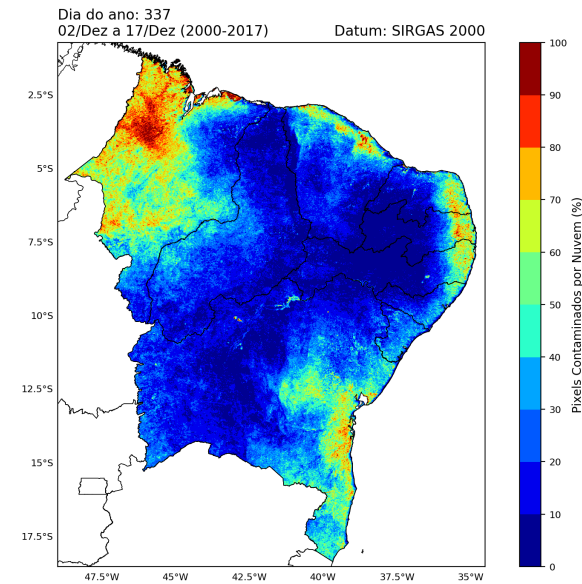
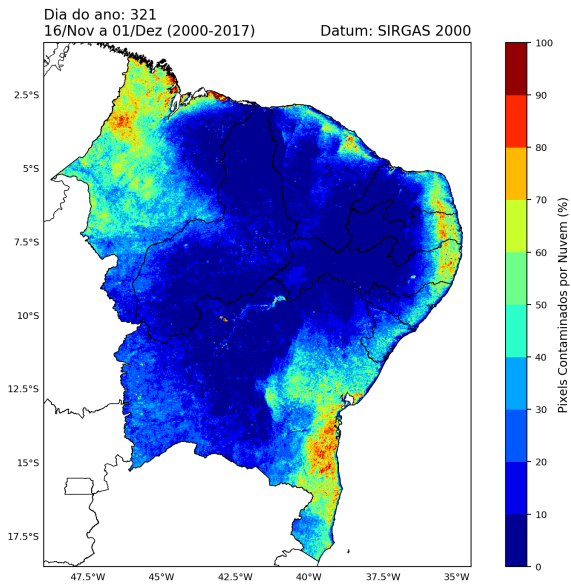
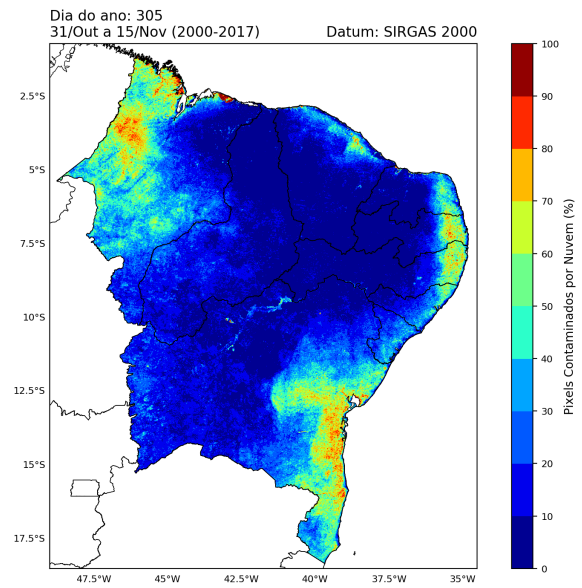
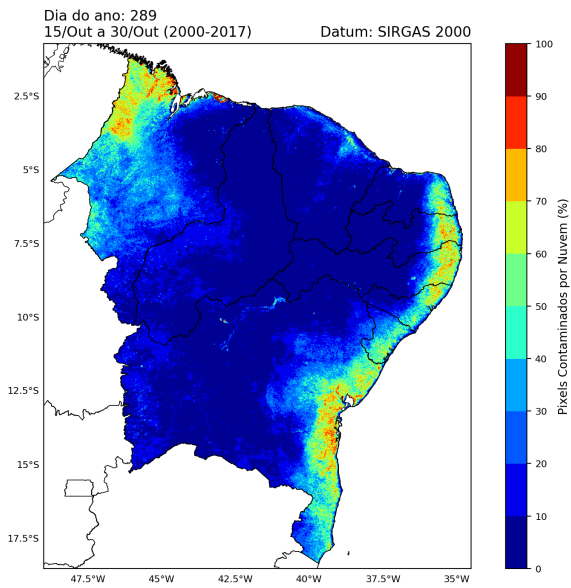


Dia do ano: 257
13/Set a 28/Set (2000-2017) Datum: SIRGAS 2000

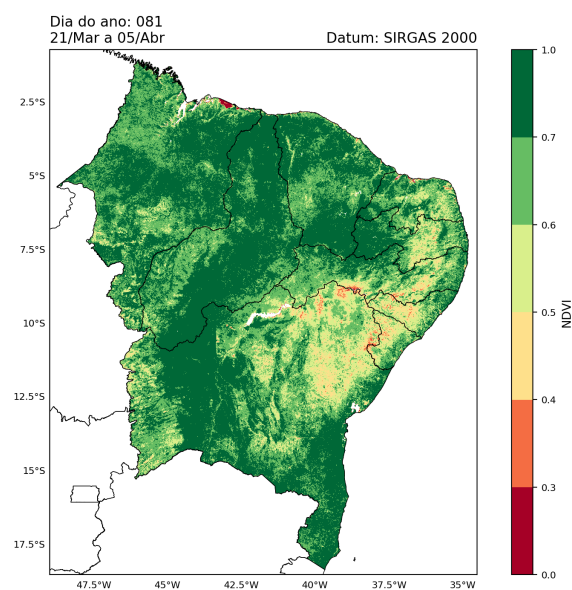

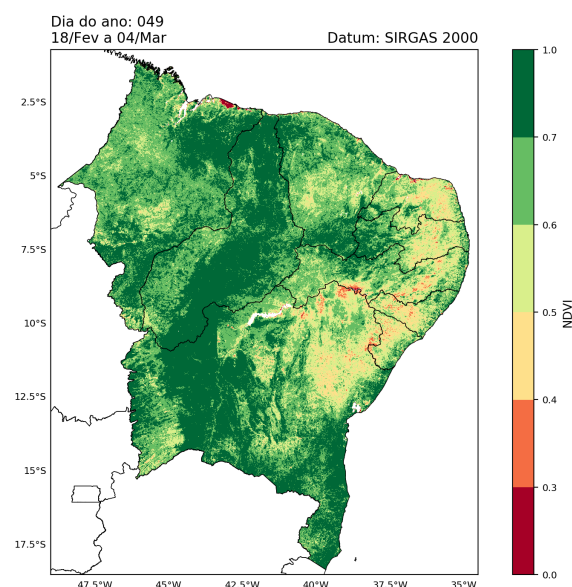
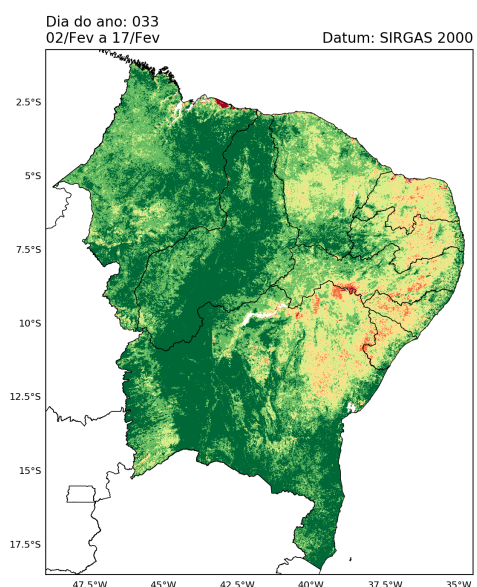
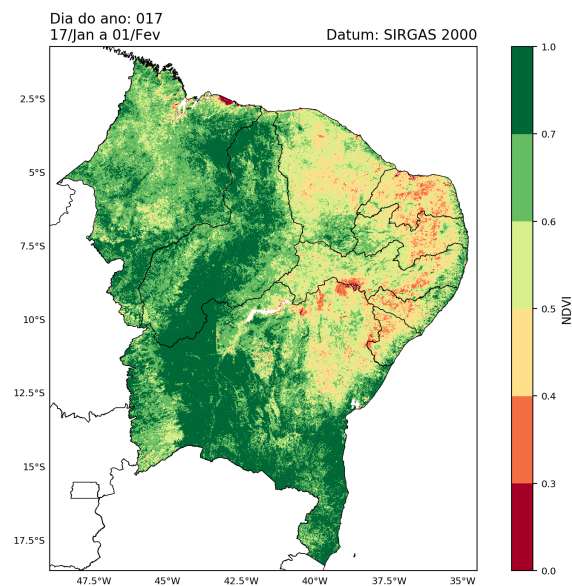
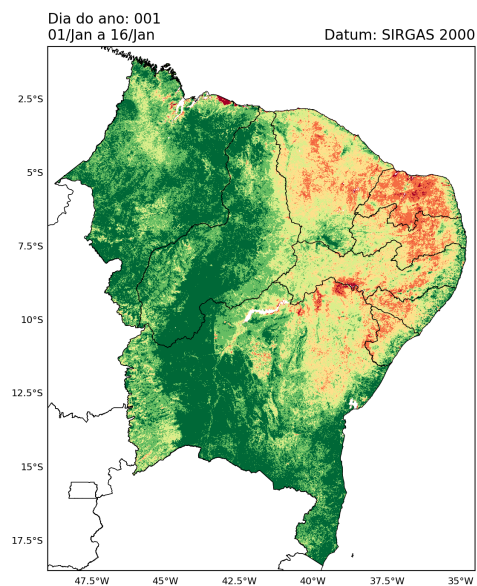


Dia do ano: 273
29/Set a 14/Out (2000-2017) Datum: SIRGAS 2000







APÊNDICE D - FIGURAS DO NDVI MÉDIO




Dia do ano: 097
06/Abr a 21/Abr Datum: SIRGAS 2000




Dia do ano: 113
22/Abr a 07/Mai Datum: SIRGAS 2000




Dia do ano: 129
08/Mai a 23/Mai Datum: SIRGAS 2000




Dia do ano: 145
24/Mai a 08/Jun Datum: SIRGAS 2000




Dia do ano: 161
09/Jun a 24/Jun Datum: SIRGAS 2000



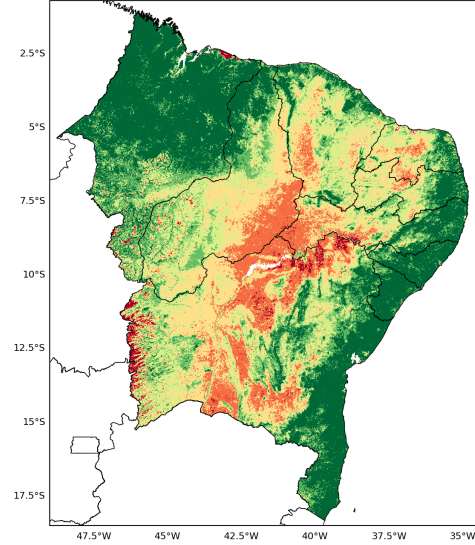
Dia do ano: 177
25/Jun a 10/Jul Datum: SIRGAS 2000



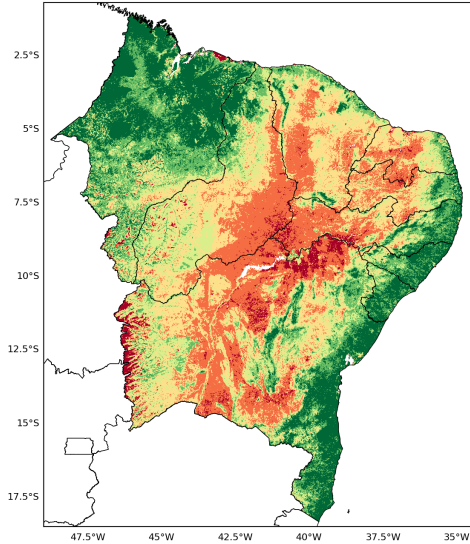
Dia do ano: 193
11/Jul a 26/Jul Datum: SIRGAS 2000



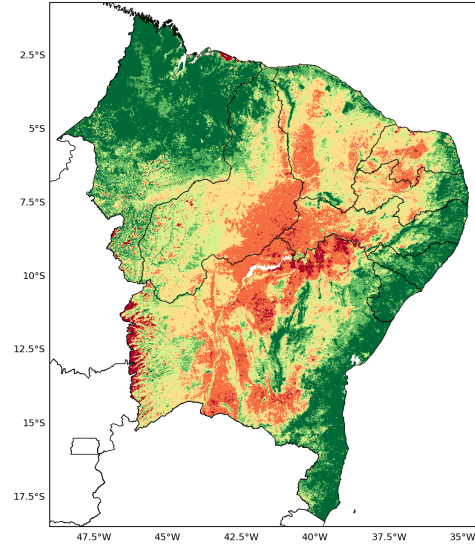
Dia do ano: 209
27/Jul a 11/Ago Datum: SIRGAS 2000



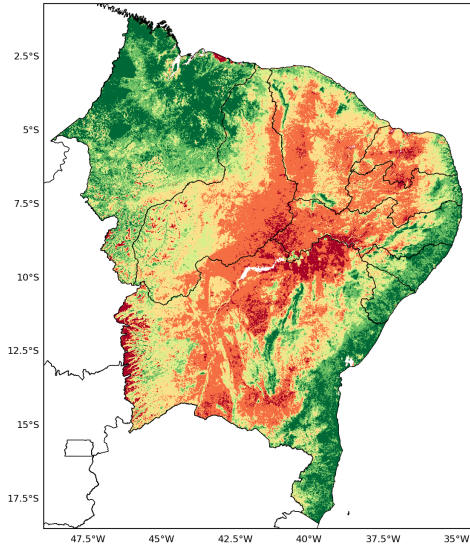
Dia do ano: 241
28/Ago a 12/Set Datum: SIRGAS 2000



Dia do ano: 225
12/Ago a 27/Ago Datum: SIRGAS 2000



Dia do ano: 257
13/Set a 28/Set Datum: SIRGAS 2000



Dia do ano: 273
29/Set a 14/Out Datum: SIRGAS 2000

