



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

sid.inpe.br/mtc-m21d/2024/01.11.16.58-TDI

**EFEITOS DE ILUMINAÇÃO SOLAR EM ATRIBUTOS  
ESPECTRO-ESPACIAIS DA CONSTELAÇÃO  
PLANETSCOPE OBTIDOS NA AMAZÔNIA**

Caio Arlanche Petri

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Lenio Soares Galvão, e Luiz Eduardo de Oliveira e Cruz de Aragão, aprovada em 15 de dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AH9P78>>

INPE  
São José dos Campos  
2023

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE  
Coordenação de Ensino, Pesquisa e Extensão (COEPE)  
Divisão de Biblioteca (DIBIB)  
CEP 12.227-010  
São José dos Campos - SP - Brasil  
Tel.:(012) 3208-6923/7348  
E-mail: pubtc@inpe.br

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**

**Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

**Membros:**

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)  
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)  
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)  
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon  
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

**EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



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

sid.inpe.br/mtc-m21d/2024/01.11.16.58-TDI

**EFEITOS DE ILUMINAÇÃO SOLAR EM ATRIBUTOS  
ESPECTRO-ESPACIAIS DA CONSTELAÇÃO  
PLANETSCOPE OBTIDOS NA AMAZÔNIA**

Caio Arlanche Petri

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Lenio Soares Galvão, e Luiz Eduardo de Oliveira e Cruz de Aragão, aprovada em 15 de dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AH9P78>>

INPE  
São José dos Campos  
2023

Dados Internacionais de Catalogação na Publicação (CIP)

---

Petri, Caio Arlanche.

P448e Efeitos de iluminação solar em atributos espectro-espaciais da constelação planetscope obtidos na Amazônia / Caio Arlanche Petri. – São José dos Campos : INPE, 2023.  
xx + 98 p. ; (sid.inpe.br/mtc-m21d/2024/01.11.16.58-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientadores : Drs. Lenio Soares Galvão, e Luiz Eduardo de Oliveira e Cruz de Aragão.

1. Constelações de satélites. 2. Iluminação solar. 3. Alta resolução espacial. 5. Amazônia. I.Título.

CDU 528.8:523.1(811)

---



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

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



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÃO



**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**  
Serviço de Pós-Graduação - SEPGR

**DEFESA FINAL DE TESE DE CAIO ARLANCHE PETRI**  
**REG. 142336/2019, BANCA Nº 303/2023**

No dia 15 de dezembro de 2023, em formato híbrido, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Doutor em Sensoriamento Remoto, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

**Título:** EFEITOS DE ILUMINAÇÃO SOLAR EM ATRIBUTOS ESPECTRO-ESPACIAIS DA CONSTELAÇÃO PLANESCOPE OBTIDOS NA AMAZÔNIA

**Membros da banca:**

Dr. Thales Sehn Körting – Presidente – INPE

Dr. Lenio Soares Galvão – Orientador – INPE

Dr. Luiz Eduardo de Oliveira e Cruz de Aragão – Orientador – INPE

Dr. Yhasmin Mendes Moura – Membro Externo – UN-FAO

Dr. Fábio Marcelo Breunig – Membro Externo – UFPR



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 28/12/2023, às 19:18 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lênio Soares Galvão, Pesquisador**, em 10/01/2024, às 08:39 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Marcelo Breunig (E), Usuário Externo**, em 23/01/2024, às 14:13 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luiz Eduardo Oliveira E Cruz de Aragão, Chefe da Divisão de Observação da Terra e Geoinformática**, em 02/02/2024, às 16:38 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Yhasmin mendes de moura (E), Usuário Externo**, em 06/02/2024, às 05:09 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11591848** e o código CRC **1E24E357**.

---

**Referência:** Processo nº 01340.010396/2023-18

SEI nº 11591848

*“Queria uma vida fútil  
Deixando o que for tão útil  
Levando comigo as mágoas  
De uns dias madrugadas...”*



## AGRADECIMENTOS

Dentre os diversos agradecimentos que devo às pessoas que contribuíram de alguma forma para que essa tese fosse possível, de forma direta e indireta, devo inicialmente destacar, sem dúvidas, a parceria profissional e pessoal que já acumula mais de seis anos com meu orientador, Lênio. Sem a confiança depositada em meu trabalho durante o mestrado, doutorado e desafios que a vida colocou durante todo esse período, tenho a certeza de que nada teria sido possível. Minha gratidão por essa oportunidade será eterna.

Ao meu co-orientador, Luiz Aragão, devo o agradecimento pelas sábias contribuições e, também, pela sincera amizade durante todos os anos de minha trajetória no INPE. Agradeço também aos colegas Ricardo, Catherine e Fábio pelas valiosas discussões durante o processo de criação deste trabalho. À Ieda e Thales também, claro, que em momentos distintos ofereceram sua orientação para o aprimoramento deste trabalho.

Agradeço à minha companheira, Ana Paula, por tudo. Não há tema ou assunto que caiba em palavras para precisar a que devo agradecer quando se trata de uma parceria tão completa, compreensiva e colaborativa em minha vida.

Devo um agradecimento especial à minha família, especialmente minha mãe, Silvana, meu pai, Roberto, e meu irmão, Felipe. Acreditar e apoiar uma trajetória acadêmica nem sempre é simples. Felizmente, tive o privilégio de ser incentivado a seguir em frente, sempre.

Os amigos que me ofereceram suporte para esse processo são muitos. A turma 2017, a turma 2019, a turma da sala ASA 35, da sala ASA 58, dos churrascos, das bandas, almoços e jantares. Quando se trata de um grupo que foi tão importante para me tornar a pessoa que sou hoje, prefiro não ordenar nomes de forma específica. Mas um nome deve ser citado, o Denis, por não só fazer parte desse grupo tão especial, mas também ter participação direta em minha trajetória profissional durante esse processo.

Agradeço ainda à SCCON Geospatial pela sessão das imagens Planet utilizadas neste trabalho. Representada nas figuras de Afonso Oliveira e Lara Musse Felix, as discussões e apoio foram fundamentais para o desenvolvimento da tese.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## RESUMO

Estudos fenológicos da vegetação por sensoriamento remoto orbital na Amazônia são limitados pela pouca disponibilidade de dados multitemporais, com observações de alta resolução espacial regularmente espaçadas no tempo. O recente advento das constelações de satélites poderá suprir parte destas limitações. No entanto, quando a alta resolução espacial é utilizada em estudos de fenologia das florestas tropicais da Amazônia, os efeitos das condições de iluminação solar e do terreno podem ser críticos para a determinação de alguns atributos espaciais e espectrais das imagens. Não há, contudo, estudos que abordem os efeitos de iluminação solar em dados de constelações de satélites obtidos ao nadir na Amazônia. Este trabalho, portanto, teve como objetivo a investigação de efeitos da geometria de iluminação solar em dados de alta resolução espacial obtidos pela constelação PlanetScope (PS) em florestas tropicais da Amazônia. Para isso, utilizaram-se séries temporais, compostas por um total de 493 imagens PS, livres de cobertura nuvens. As imagens foram obtidas entre os anos de 2017 e 2019 sobre 12 áreas de estudo, abrangendo regiões ao norte e ao sul deste bioma. O processo analítico baseou-se na observação da geometria de iluminação solar, durante a aquisição de dados PS na estação seca (Junho a Setembro), e das relações entre ângulos solares com: (i) atributos espectrais de imagens PS, representados por valores de reflectância, índices de vegetação (IVs) (Enhanced Vegetation Index - EVI e Normalized Difference Vegetation Index - NDVI), brilho da vegetação, determinado da análise por componentes principais (ACP) e por frações-sombra extraídas de um modelo linear de mistura espectral (MLME); e (ii) atributos espaciais de imagens PS, representados por métricas de textura Gray-Level Co-occurrence Matrix (GLCM). Os resultados mostraram que o aumento no ângulo zenital solar (AZS) e a redução no ângulo azimutal solar (AAS), em direção ao final da estação seca, produziu um incremento consistente na reflectância das quatro bandas do PS, especialmente na banda do infravermelho próximo (IVP). De forma concordante, o brilho da vegetação aumentou de junho para setembro, conforme registrado pelos valores da primeira componente principal (CP1). O EVI, índice mais anisotrópico e fortemente dependente da reflectância do IVP, apresentou valores mais altos em direção a setembro, acompanhando as variações nos ângulos solares. O NDVI, ao contrário, foi pouco correlacionado com estes ângulos. A média da textura GLCM apresentou incremento do início para o final da estação seca, enquanto a variância da textura diminuiu no mesmo período. Foram observadas correlações estatisticamente significantes entre as métricas de textura GLCM e os ângulos solares. O EVI apresentou alta correlação com a média GLCM da textura da banda do IVP do PS, ao contrário do observado para o NDVI. As frações-sombra, resultantes das variações de iluminação entre as copas das árvores e no terreno, diminuíram na direção do final da estação seca. Estas frações foram correlacionadas com o EVI, mas não com o NDVI. Em geral, os resultados destacaram a importância da

correção dos efeitos de iluminação solar e, em alguns casos, de iluminação do terreno, se IVs anisotrópicos como o EVI forem utilizados em estudos de fenologia da vegetação com dados de alta resolução espacial do PS.

Palavras-chave: Constelações de satélites. Iluminação solar. Alta resolução espacial. Amazônia.

# **SOLAR ILLUMINATION EFFECTS ON SPECTRAL-SPATIAL ATTRIBUTES OF THE PLANETSCOPE CONSTELLATION OBTAINED IN THE AMAZON**

## **ABSTRACT**

Vegetation phenological studies using orbital remote sensing in the Amazon are hampered by the limited availability of high spatial resolution data and the analysis of regularly spaced time series observations. The recent advent of satellite constellations may overcome some of these limitations. However, when high spatial resolution is used in phenology studies of Amazonian tropical forests, the effects of solar and terrain illumination conditions can be important in determining spatial and spectral attributes from images. In this scenario, there are currently no studies addressing the effects of solar illumination on data from satellite constellations obtained at nadir in the Amazon. This work aimed to investigate the effects of solar illumination geometry on high spatial resolution data obtained by the PlanetScope (PS) constellation in tropical forests of the Amazon. A time series from a total of 493 PS cloud-free images was used. The images were obtained between 2017 and 2019 over 12 study areas, covering regions from the north and south of this biome. The analytical process was based on the observation of solar illumination geometry during the acquisition of PS data in the dry season (June to September), and the relationships between solar angles with: (i) spectral attributes of PS images, represented by reflectance values, vegetation indices (VIs) (Enhanced Vegetation Index - EVI and Normalized Difference Vegetation Index - NDVI), vegetation brightness, determined from a principal component analysis (PCA), and shade fractions extracted from a linear spectral mixture model (LSMM); and (ii) spatial attributes of PS images, represented by Gray-Level Co-occurrence Matrix (GLCM) texture metrics. The results showed that the increase in the solar zenith angle (SZA) and the reduction in the solar azimuth angle (SAA), towards the end of the dry season, produced a consistent increase in the reflectance of the four PS bands, especially in the near-infrared band (NIR). Concordantly, vegetation brightness increased from June to September, as recorded by the scores of the first principal component (PC1). The EVI, a more anisotropic index and strongly dependent on NIR reflectance, showed higher values towards September, following variations in solar angles. NDVI, on the contrary, was poorly correlated with these angles. The average GLCM texture increased from the beginning to the end of the dry season, while the texture variance decreased in the same period. Statistically significant correlations were observed between GLCM texture metrics and solar angles. The EVI showed a high correlation with the GLCM average of the PS NIR band texture, contrary to what was observed for the NDVI. Shade fractions, resulting from variations in illumination of tree canopies and terrain, decreased towards the end of the dry season. These fractions were correlated with EVI, but not with NDVI. Overall, the results highlighted the importance of correcting for solar

illumination effects, and in some cases terrain illumination, if anisotropic VIs such as EVI are to be used in vegetation phenology studies with high spatial resolution data of PS.

Keywords: Satellite constellations. Solar illumination. High spatial resolution. Amazon.

## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Exemplo de recorte do produto MODIS (MAIAC) para o EVI somente para a correção atmosférica sem efeitos bidirecionais.....	11
Figura 2.2 - Frequência relativa de pixels de alta qualidade, ângulo zenital de visada e ângulo zenital solar para áreas no norte (site 1), centro (site 2) e sul (site 3) da Amazônia. ....	13
Figura 2.3 - Frequência relativa de observações de pixels de alta qualidade selecionados no produto MAIAC para a Amazônia em junho (2000-2014).....	14
Figura 2.4 - Frequência relativa de observações em retroespalhamento para a Amazônia. ....	15
Figura 2.5 - Ângulo azimutal relativo de observações do MODIS na Amazônia ao longo do ano.....	15
Figura 2.6 - EVI, NDVI, SWND e PRI corrigidos e não corrigidos para efeitos bidirecionais pelo MAIAC ao longo da estação seca na Amazônia (2000-2014). .....	16
Figura 2.7 - Resposta espectral relativa das bandas dos sensores PS. ....	21
Figura 2.8 - ACP aplicada para dados MODIS em diferentes fitofisionomias e durante a estação seca na Amazônia. ....	26
Figura 3.1 - Fluxograma metodológico de seleção de áreas de estudo, aquisição de bases de dados e processos analíticos desenvolvidos no trabalho. ....	29
Figura 3.2 - Localização das 12 áreas de estudo (5 x 5 km) selecionadas para a análise de dados na Amazônia brasileira. À direita, as 12 áreas de estudo são apresentadas com composição verdadeira utilizando dados PS .....	30
Figura 3.3 - Frequência de observações livres de nuvens entre 2017 e 2019 para cada uma das 12 áreas de estudo selecionadas na Amazônia. ....	35
Figura 4.1 - Déficit hídrico máximo acumulado ( <i>Maximum cummulative water deficit</i> - MCWD) histórico (1981 – 2020) médio, representado em mm/ano, para o bioma Amazônia.....	43

Figura 4.2 - Mudanças no ângulo zenital solar (AZS) e ângulo azimutal solar (AAS) durante a aquisição de imagens PlanetScope (PS) do início (DOI 152) para o final (DOI 272) da estação seca na Amazônia. ....	46
Figura 4.3 - Mudanças por localização da área de estudo na amplitude do ângulo zenital solar (AZS) e ângulo azimutal solar (AAS) durante a aquisição de imagens PlanetScope (PS) no começo e no final da estação seca. ....	47
Figura 4.4 - Primeiros dois valores da Análise por Componentes Principais (ACP) aplicada a dados de reflectância de superfície das quatro bandas PlanetScope. ....	50
Figura 4.5 - Variações sazonais na reflectância de superfície média da banda 3 dos dados PS (vermelho) calculada para cada área de estudo entre 2017 e 2019. ....	51
Figura 4.6 - Variações sazonais na reflectância média do NIR (banda 4) de dados PS calculadas para cada área de estudo entre 2017 e 2019. ....	52
Figura 4.7 - Variação sazonal do (a) EVI e (b) NDVI médios, calculados a partir de dados PlanetScope na área de estudo QRN. ....	53
Figura 4.8 - Variação sazonal do NDVI médio, calculado a partir de dados PlanetScope para todas as áreas de estudo. ....	54
Figura 4.9 - Variação sazonal do EVI médio, calculado a partir de dados OLI/Landsat-8 para todas as áreas de estudo. ....	55
Figura 4.10 - Variação sazonal do NDVI médio, calculado a partir de dados OLI/Landsat-8 para todas as áreas de estudo. ....	57
Figura 4.11 - Curvas do NDVI para o ano de 2017 utilizando dados PS (3.7 m de resolução espacial) e Landsat (30 m). ....	59
Figura 4.12 - Relações entre o EVI e (a) ângulo zenital solar (AZS) e (b) ângulo azimutal solar (AAS) utilizando as 12 áreas de estudo selecionadas. ....	60
Figura 4.13 - Variações na média de textura GLCM durante a estação seca para as áreas (a) SNP e (b) SFX. Resultados para a variância da textura GLCM das mesmas áreas estão ilustradas em (c) e (d). ....	61
Figura 4.14 - Variações na média de textura GLCM durante a estação seca para as doze áreas de estudo. ....	62

Figura 4.15 - Variações na variância de textura GLCM durante a estação seca para as doze áreas de estudo.....	63
Figura 4.16 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo QRN utilizando dados PlanetScope.....	64
Figura 4.17 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo PVL utilizando dados PlanetScope.....	64
Figura 4.18 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo SNP utilizando dados PlanetScope.....	65
Figura 4.19 - Variações na média de textura GLCM do OLI/Landsat-8 durante a estação seca para as doze áreas de estudo.....	66
Figura 4.20 - Variações na variância de textura GLCM dos dados OLI/Landsat-8 durante a estação seca para as doze áreas de estudo.....	67
Figura 4.21 - Variações espacializadas nas métricas de textura média e variância do OLI/Landsat-8 para a área de estudo QRN.....	68
Figura 4.22 - Relações entre as médias da textura GLCM PS com o ângulo zenital solar (AZS) e o ângulo azimutal solar (AAS) em (a) e (b), respectivamente. Os resultados correspondentes para a variância da textura estão em (c) e (d).....	69
Figura 4.23 - Relações da média da textura GLCM PS com (a) EVI e (b) NDVI..	70
Figura 4.24 - <i>Endmembers</i> selecionados para compor o MLME a partir de dados PS.....	71
Figura 4.25 - Imagens do MLME em composição colorida para dados PS obtidos em junho. A composição RGB foi obtida com as frações solo/NPV, vegetação verde e sombra, respectivamente.....	72
Figura 4.26 - Composição total entre frações vegetação verde, solo/matéria seca e sombra para onze áreas de estudo em junho.....	73
Figura 4.27 - Variações nas imagens frações-sombra PlanetScope do início (junho) para o final (setembro) da estação seca na Amazônia para as áreas de estudo MN2 e QRN.....	75
Figura 4.28 - Variações nas imagens frações-sombra PlanetScope e OLI/Landsat-8 do início (junho) para o final (setembro) da estação seca na	

Amazônia para as áreas de estudo MN2. Resultados para julho foram omitidos devido a ausência de observações válidas. ....	76
Figura 4.29 - Correlações das frações-sombra do PS com valores de (a) EVI e (b) NDVI. ....	77
Figura 4.30 - Representação de imagens PS em composição falsa-cor usando as bandas 4(R)3(G)2(B) para a área de estudo PVL entre maio e outubro de 2019. ....	78
Figura 4.31 - Comportamento sazonal de pixels de solo exposto para a área de estudo QRN para (a) azul, verde, vermelho e NIR para dados PS obtidos em todo o ano de 2018; e (b) EVI e NDVI. ....	79

## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 - Características principais das 12 áreas de estudo selecionadas na Amazônia brasileira. Os dados de solo são baseados em Quesada et al. (2011). A precipitação anual média e temperatura anual média foram derivadas do WorldClim v2 (Fick e Humans, 2017), enquanto que a biomassa média foi calculada por Almeida et al. (2019). A altitude local e a média de altura do dossel foram medidas por LiDAR aerotransportado. As abreviaturas para os tipos de floresta são: SFO (floresta ombrófila sazonalmente inundada), TFO (floresta ombrófila de terra firme), e TFT (floresta ombrófila de transição). ....	32
Tabela 4.1 - Variações no déficit hídrico máximo acumulado (ou <i>maximum cumulative water deficit</i> , MCWD) nas áreas de estudo entre 2017 e 2019. Áreas localizadas ao leste (QRN, SNP, AFL e TAP) apresentaram maior estresse hídrico quando comparadas às áreas a oeste (MN1, MN2 e URN). .....	44
Tabela 4.2 – Autovetores resultantes da Análise por Componentes Principais (ACP) aplicada para observações PlanetScope, em valores de reflectância, na estação seca das áreas MN2 e QRN. ....	49



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO .....</b>	<b>1</b>
1.1 Objetivo geral .....	6
1.2 Objetivos específicos .....	6
1.3 Estrutura da tese .....	7
<b>2 FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>9</b>
2.1 Estudos de fenologia da vegetação na Amazônia com dados satelitais .....	9
2.2 Secas na Amazônia e o cálculo do déficit hídrico acumulado .....	17
2.3 Pré-processamento de imagens para estudos da vegetação com séries temporais.....	18
2.4 Constelações de satélites PS e séries temporais.....	20
2.5 Técnicas de análise de imagens de sensoriamento remoto para florestas tropicais.....	22
<b>3 METODOLOGIA.....</b>	<b>29</b>
3.1 Seleção das áreas de estudo .....	30
3.2 Avaliação do MCWD para as áreas de estudo.....	33
3.3 Obtenção de imagens de satélites .....	33
3.4 Análise de dados de atributos espaciais e espectrais .....	36
3.5 Comparação dos dados PS com dados Landsat .....	41
<b>4 RESULTADOS .....</b>	<b>42</b>
4.1 Déficit hídrico acumulado na Amazônia entre 2017 e 2019 .....	42
4.2 Geometria de aquisição de imagens PlanetScope.....	44
4.3 Mudanças em brilho, reflectância e IVs na estação seca.....	48
4.4 Variações em métricas de textura (GLCM) na estação seca .....	60
4.5 Variações em frações-sombra e sensibilidade de IVs às condições de iluminação da vegetação e terreno durante a estação seca .....	70
<b>5 DISCUSSÃO .....</b>	<b>80</b>
<b>6 CONCLUSÕES .....</b>	<b>86</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>90</b>



## 1 INTRODUÇÃO

A Amazônia abriga a maior área de floresta tropical contínua e preservada do mundo, possuindo um papel essencial no ciclo global de carbono e, conseqüentemente, na regulação do clima (GATTI et al., 2021). Estudos de fenologia da vegetação na Amazônia por satélites são importantes para a compreensão das respostas da cobertura vegetal diante de variações climáticas atuais e dos cenários de mudanças climáticas previstos. Estes cenários incluem mudanças ambientais nos ecossistemas decorrentes de eventos climáticos extremos, que serão cada vez mais frequentes e severos (BAJOCCO et al., 2019; JIMÉMEZ-MUÑOZ et al., 2016; MARENGO et al., 2012). Entretanto, quando comparado com estudos com levantamentos *in situ*, a análise fenológica com sensores orbitais apresenta limitações para fornecer informações detalhadas sobre as condições do dossel. Em contrapartida, mesmo considerando estas limitações, o sensoriamento remoto é a única fonte viável de informação para estudos em florestas tropicais em larga escala, complementando as informações obtidas em campo (SANTOS et al., 2014; MEELAS et al., 2013).

Nos últimos anos, resultados discordantes sobre o comportamento do *Enhanced Vegetation Index* (EVI), diante de eventos de secas severas na Amazônia, iniciaram um debate importante sobre a resiliência de florestas tropicais às mudanças climáticas (SALESKA et al., 2007; SAMANTA et al., 2010; ATKINSON et al., 2011; XU et al., 2011). O avanço no entendimento do comportamento do EVI consolidou a ideia de que nem mesmo a variabilidade sazonal do EVI, que aumenta do início para o final da estação seca na Amazônia, sob condições mais acentuadas de estresse hídrico e disponibilidade de radiação solar, era um fenômeno natural, descorrelacionado da geometria de aquisição dos dados orbitais (MOURA et al., 2012; MORTON et al., 2014). Vale ressaltar que as observações oriundas de satélites em estudos da vegetação, em larga escala, têm sido realizadas, preferencialmente, com sensores de alta resolução temporal, como o MODIS (*Moderate Resolution Imaging Spectroradiometer*). O MODIS possui um amplo campo de visada ( $\pm 55^\circ$  do nadir; 2.300 km de faixa de imageamento) e uma resolução espacial moderada (250 m a 1 km) (FRIEDL; SULLA-MENASHE, 2015). Tais

características tornam o MODIS um sensor muito mais suscetível aos efeitos bidirecionais, já que inclui variações, mesmo em suas composições de 8 ou 16 dias, em parâmetros como direção de imageamento e ângulo de visada.

Como ressaltado, os primeiros estudos fenológicos das florestas da Amazônia, a partir de observações derivadas do MODIS, apontaram para um aumento do EVI do início para o final da estação seca, em condições de déficit hídrico crescente e maior iluminação solar (HUETE et al., 2006; GALVÃO et al., 2011; MOURA et al., 2017). Em virtude de sua extensão territorial, a estação seca varia na Amazônia, a depender da localização geográfica e das condições de precipitação pluviométrica que são distintas do Leste para o Oeste da região. Entretanto, o período entre junho e setembro é, geralmente, o mais representativo da estação seca em toda a região (MOURA et al., 2015).

Os possíveis fatores que podem explicar a variabilidade sazonal do EVI incluem fatores biofísicos (verdeamento ou *leaf flushing*; mudanças no índice de área foliar (IAF) ou em demografia foliar; e modificações na estrutura do dossel e nas sombras associadas à mortalidade de árvores) (MYNENI et al., 2007; SALESKA et al., 2007; ANDERSON et al., 2010; BRANDO et al., 2010; WU et al., 2016; MOURA et al., 2017), e fatores não biofísicos (efeitos bidirecionais do MODIS na determinação do EVI) (GALVÃO et al., 2011; MOURA et al., 2012; MORTON et al., 2014; PETRI; GALVÃO, 2019).

Nesse contexto, alguns estudos têm proposto como solução para a influência de fatores não biofísicos, a utilização de dados MODIS com correção de efeitos bidirecionais. Contudo, mesmo após a correção desses efeitos nos dados MODIS, os resultados têm apresentado divergências, onde um sinal de EVI aproximadamente constante ou com incrementos do início para o final da estação seca tem sido divergentemente registrado (MORTON et al., 2014; WU et al., 2016; MOURA et al., 2017; PETRI et al., 2019). Parte dessas incertezas na interpretação dos dados é produzida pela maior sensibilidade do EVI a efeitos bidirecionais quando comparado com outros índices de vegetação (IVs) menos anisotrópicos, como o *Normalized Difference Vegetation Index* (NDVI). O EVI é majoritariamente influenciado por mudanças na reflectância do infravermelho próximo (NIR), enquanto o NDVI é resultante de uma diferença normalizada com pesos iguais tanto para a reflectância da banda do NIR,

quanto para a reflectância da banda do vermelho (GALVÃO et al., 2011; MOURA et al., 2017). Diferenças normalizadas em formulações de IVs, em geral, tendem a reduzir os efeitos bidirecionais, incluindo os de iluminação solar.

Outra parte das incertezas é gerada por efeitos de geometria de visada e iluminação solar, resultantes do amplo campo de visada (*Field-of-View*, FOV) do MODIS. Esta característica também gera dificuldades para um pré-processamento preciso de seus dados, incluindo a criação de máscaras de nuvens e a correção atmosférica. Instrumentos satelitais com amplo campo de visada possuem como vantagem um período de revisita constante de suas cenas, produzindo observações de baixa a moderada resolução espacial com frequência diária. Por outro lado, esse tipo de instrumento possui a desvantagem de adquirir dados com ângulo zenital de visada (AZV) e direção de imageamento (retro-espalhamento ou espalhamento frontal) variáveis. Portanto, as imagens adquiridas pelo MODIS são muito mais sensíveis aos efeitos bidirecionais quando comparadas à obtenção de dados com visada ao nadir. Assim, para se obter observações orbitais com resolução espacial mais fina que a resolução do MODIS e com visada ao nadir, é necessária a utilização de sensores com campo de visada mais estreito, o que resulta na diminuição da frequência de revisita da cena ou na resolução temporal.

Neste contexto, é importante mencionar a existência de missões históricas da família Landsat de satélites, com uso de múltiplos sensores, que estabeleceram padrões significativos de classificação de uso e ocupação da terra na Amazônia. Desde 1972, anterior ao início da operação do sensor MODIS, lançado em 1999, os satélites da série Landsat possibilitaram o desenvolvimento de importantes estudos para a compreensão das dinâmicas ambientais e sócio territoriais, por meio do acúmulo de observações, bem como para o suporte no estabelecimento de políticas públicas sobre o bioma. Entretanto, a persistente cobertura de nuvens da região, especialmente durante a estação chuvosa, e na porção norte da Amazônia, dificultou o uso do Landsat em estudos multitemporais de fenologia da vegetação. Apesar desta limitação, suas características multiespectrais e visada ao nadir permitiram a construção de parte significativa do conhecimento sobre as florestas tropicais na Amazônia

e sua proteção ao longo dos anos. Como exemplo disso, destaca-se o programa nacional PRODES (Programa de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite), com foco em quantificação das taxas de desmatamento.

O advento recente das constelações de satélites para observação da Terra, especialmente a partir de 2016, constitui um marco na história do sensoriamento remoto. As constelações de satélites são uma importante fonte de dados que podem resolver as condições excludentes (*trade-offs*) entre resoluções temporais e espaciais utilizando visada ao nadir. Quando comparadas, por exemplo, com dados MODIS, tais constelações reduzem, em princípio, os efeitos de ângulo de visada e da direção de imageamento na aquisição dos dados, mas não os de iluminação solar que poderão ser realçados sob alta resolução espacial. Adicionalmente, constelações de satélites fornecem uma perspectiva sem precedentes para a observação de variações em atributos espaciais e espectrais, calculados em altas resoluções espacial e temporal, durante a estação seca na Amazônia, o período que tem gerado controvérsias na análise de dados EVI do MODIS.

Um exemplo de conjunto de dados oriundos de constelações de satélites é o PlanetScope (PS), composto por centenas de pequenos CubeSats padronizados (BREUNIG et al., 2020; WANG et al., 2020). Essa constelação possui, atualmente, mais de 180 *CubeSats* (em tamanho de 10x10x30 cm e peso aproximado de 4kg, em sua maioria obedecendo órbita sol-síncrona a 465 km de altitude (PLANET LABS, 2023). Desde sua primeira geração em 2016, a constelação de satélites PS adquire imagens diárias em resolução espectral de quatro bandas (três bandas no visível e uma no NIR) e resolução espacial de 3,7 m. A partir das séries temporais da constelação PS, é possível calcular o NDVI e o EVI, que, conforme discutido anteriormente, possuem diferentes graus de anisotropia aos efeitos bidirecionais, bem como diferentes sensibilidades aos parâmetros biofísicos do dossel.

Mesmo utilizando sensores PS com visada ao nadir para produzir séries temporais, são esperados efeitos de iluminação solar na aquisição de imagens durante a estação seca na Amazônia. Entretanto, observa-se na literatura a ausência de estudos que investiguem a magnitude desses efeitos com dados

de constelações de satélites para essa região. Estudos mostram que, por exemplo, em áreas localizadas na porção sul da Amazônia, a amplitude do ângulo zenital solar (AZS) entre o início e o final da estação seca pode atingir valores de até 18° (GALVÃO et al., 2011; PETRI; GALVÃO, 2019). Além disso, observou-se que o ângulo azimutal solar (AAS) também apresenta variações durante a aquisição de dados PS na estação seca. Ambos os ângulos (AZS e AAS) podem afetar a quantidade de sombras projetadas pelo dossel que são observadas ao longo do tempo pela constelação de satélites, produzindo mudanças em atributos de métricas espectrais (reflectância, brilho da vegetação, índices de vegetação e frações-sombra) e espaciais (métricas de textura). Quando os atributos da vegetação são calculados, utilizando uma janela móvel pequena a partir de conjuntos de dados de imagens de alta resolução espacial, métricas de textura do tipo *Gray Level Co-occurrence Matrix* (GLCM), como média da textura e variância, são fortemente associadas à estrutura da vegetação e às sombras do dossel observadas pelos sensores (HARALICK et al., 1973; WOOD et al., 2012; ZHOU et al., 2017).

Estudos recentes com base em outras fitofisionomias (Austrália) encontraram resultados que confirmam a influência da sazonalidade do AZS na determinação de IVs (MA et al., 2020). Tais resultados refletem a importância do avanço de estudos aplicados em florestas tropicais da Amazônia, uma vez que os efeitos globais da sazonalidade solar ligada à diferentes latitudes precisam ser posicionados em diferentes fitofisionomias que, em aspectos físicos e fenológicos, podem gerar importantes contribuições.

Apesar disso, carecem estudos que avaliem esse comportamento na estação seca na Amazônia usando dados PS de alta resolução espacial (BOURSCHEIDT et al. (2023). Além disso, ao se utilizar um conjunto de *endmembers* fixos em um modelo linear de mistura espectral (MLME), é possível quantificar a quantidade de sombras capturadas pelos sensores, provenientes de ambos, vegetação e terreno. Todas essas possibilidades e fatores requerem estudos analíticos que avaliem o uso das constelações de satélites, como a PS, como fonte de dados em estudos da fenologia da vegetação. Especificamente, estudos que se utilizem de tais processos estarão inseridos no contexto das discussões dos efeitos antes bidirecionais, e agora

direcionais (relacionados à iluminação). Essa avaliação pode contribuir para uma melhor compreensão da variabilidade do EVI na estação seca na Amazônia e da resiliência de florestas tropicais às mudanças climáticas, sob a perspectiva do sensoriamento remoto.

Assim, ao se utilizar esta estratégia de análise de atributos espectrais (p.ex., reflectância, brilho de análise por componentes principais, IVs e frações-sombra de um modelo linear de mistura espectral) e espaciais (métricas GLCM de textura da imagem), esta tese visa responder as seguintes questões científicas: (a) Qual é o comportamento dos atributos espectrais durante a estação seca da Amazônia em dados de alta resolução espacial obtidos pela constelação de satélites PS, com visada ao nadir, mas sob diferentes condições de iluminação solar e do terreno? Ainda, conectado com essa primeira questão, dentro de janelas de observação compatíveis, é possível comparar os resultados obtidos com dados PS para observações de média resolução espacial de dados Landsat? (b) Existem efeitos de iluminação solar que afetem diferentemente a determinação do NDVI e do EVI ao longo da estação seca? (c) Há variações na quantidade de sombras, capturadas de um MLME aplicado a dados PS, produzindo modificações na textura das imagens do início para o final da estação seca?

### **1.1 Objetivo geral**

O objetivo geral foi avaliar como os efeitos de iluminação solar afetam a determinação de atributos espectrais (reflectância, brilho, IVs e fração-sombra) e espaciais (métricas GLCM de textura), calculados a partir de séries temporais obtidas sobre 12 áreas de estudo localizadas em diferentes latitudes na Amazônia.

### **1.2 Objetivos específicos**

Para atingir este objetivo, foi utilizado um conjunto de 493 imagens PS, livres de cobertura de nuvens, obtidas principalmente durante as estações secas de 2017 a 2019. Foram analisados os impactos das variações dos ângulos solares, principalmente AZS, na obtenção destes atributos. De forma complementar, comparou-se a consistência dos resultados obtidos em alta resolução espacial (PS; 3,7 m) com atributos espaciais e espectrais calculados

a partir de dados com resolução espacial média (OLI/Landsat-8; 30 m). Especificamente, os objetivos foram:

- Investigar a geometria de iluminação solar intrínseca da aquisição de dados PlanetScope para as 12 áreas de estudo distribuídas ao longo da Amazônia;
- Analisar a influência da iluminação solar em atributos espectrais obtidos a partir de dados PS, tais como a reflectância de superfície de quatro bandas espectrais (azul, verde, vermelho e NIR); brilho da vegetação determinado de uma análise por componentes principais (ACP); IVs com diferentes níveis de anisotropia (NDVI e EVI); e frações-sombra derivadas de um MLME.
- Analisar a influência da iluminação solar no cálculo de métricas de textura GLCM obtidas a partir da banda do NIR da constelação PS;
- Avaliar, a partir de janelas viáveis de observação sem nuvens nas áreas de estudo selecionadas, a reprodutibilidade de parte das análises PS citadas para dados de resolução espacial média do OLI/Landsat-8 (30 m).

### **1.3 Estrutura da tese**

A partir dos objetivos propostos na Introdução (Capítulo 1), tem-se a seguinte estrutura para a presente tese: Fundamentação Teórica (Capítulo 2), contendo os conceitos e a literatura relevantes para as abordagens metodológicas e discussões propostas; Metodologia (Capítulo 3), onde se descreveu o processo de seleção e coleta de dados de sensoriamento remoto (PS e Landsat), assim como um conjunto auxiliar de dados MODIS, e também os métodos utilizados para as análises espectrais (reflectância, brilho, ACP, MLME) e espaciais (textura GLCM), além da obtenção de geometria de aquisição de dados; Resultados (Capítulo 4), uma seção expositiva para a descrição e avaliação de cada análise, expondo também correlações entre diferentes métricas e fornecendo subsídios para a discussão dos resultados obtidos; Discussões (Capítulo 5), onde os resultados obtidos são posicionados frente às discussões relevantes na literatura e as questões de pesquisa são respondidas a partir da

perspectiva dos dados utilizados; e Conclusões (Capítulo 6), que apresenta a síntese das respostas obtidas para as questões científicas.

## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Estudos de fenologia da vegetação na Amazônia com dados satelitais**

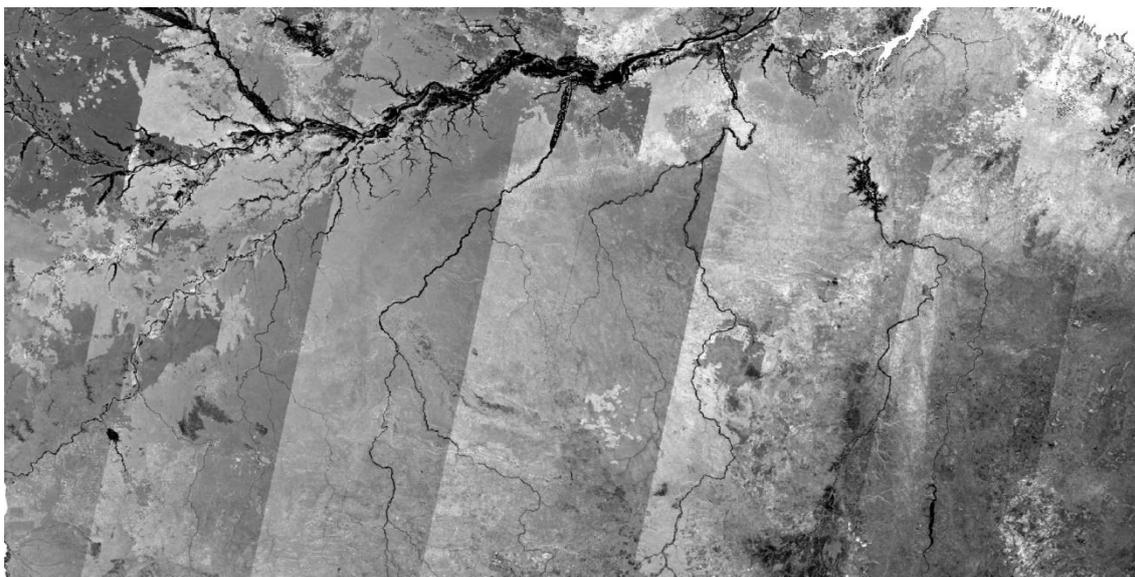
A Fenologia da vegetação pode ser definida como o estudo da vegetação e suas alterações ao longo do tempo (ARAUJO, 1970). Ou seja, mesmo que em diferentes escalas, o conceito generalizado está relacionado à sazonalidade e características intrínsecas de um indivíduo ou conjunto de formações vegetais como um todo. Sua reação e relação com elementos climáticos como secas também é um fator importante na descrição fenológica de um conjunto de florestas, por exemplo. Pode ser considerada, portanto, como uma área de pesquisa relacionada às dinâmicas temporais da vegetação. Na Amazônia, a maior parte dos estudos de fenologia da vegetação por satélites se concentra no estudo do comportamento do dossel, que é a parte da vegetação efetivamente observada pelos sistemas sensores ópticos (PETRI et al., 2019). Entretanto, é importante lembrar que o conceito de fenologia pode ser aplicado em estudos envolvendo conjuntos pequenos de dados, paisagens e biomas (MACHADO, 2017; RATHCKE; LACEY, 1985).

O sensor MODIS fornece a base de dados de satélite mais amplamente utilizada para estudos de fenologia da vegetação em escala regional na Amazônia. Mesmo em estudos com a utilização de sensores com maior resolução espacial e características espectrais distintas, o legado tecnológico e as questões científicas criadas a partir dos dados MODIS possuem relevância na contextualização dos estudos de fenologia de florestas tropicais da Amazônia. Sendo assim, cabe inicialmente apresentar as principais características desse sensor e algumas implicações decorrentes de suas especificações, antes de discorrer especificamente sobre a fenologia. O sensor MODIS, a bordo dos satélites Terra e Aqua, tem capacidade de revisita diária, fornecendo dados desde 2000 para descrever o ciclo fenológico da vegetação da Amazônia. O MODIS opera com um campo de visada de  $\pm 55^\circ$  do nadir, com uma faixa de imageamento de 2.330 km. A resolução espacial do sensor varia de 250 m (bandas 1 e 2), 500 m (bandas 3 a 7) até 1 km (bandas 8 a 36). Em contrapartida, devido a seu amplo campo de visada, a reflectância medida pelo MODIS, sazonalmente ou inter-anualmente, é influenciada pela geometria

variável de iluminação e de visada (HILKER et al., 2017). Devido ao comportamento não-Lambertiano da vegetação, sua resposta espectral, registrada pelo MODIS, varia com a posição relativa do sol e do sensor (BANDHARI et al., 2011). Em função disso, a resposta espectral é afetada por fatores como o ângulo zenital solar (AZS), o ângulo zenital de visada (AZV), o ângulo azimutal relativo (AAR) e a direção de imageamento (retro-espalhamento ou espalhamento frontal) (LYAPUSTIN et al., 2015).

A influência destes fatores é parcialmente reduzida quando imagens compostas por múltiplas datas, em intervalos de 8 ou 16 dias em um dado mês, são utilizadas para se selecionar os pixels com melhor qualidade atmosférica ou radiométrica de observação. Para a composição destas imagens, utilizam-se algoritmos de seleção que se baseiam, por exemplo, no “valor máximo” do NDVI e/ou em limiares de ângulo de visada (MEYER et al., 1995; EKLUNDH, 1995). Esta influência também é atenuada pela geração de produtos com correção dos efeitos bidirecionais, como o existente no produto MAIAC (*Multi-Angle Implementation of Atmospheric Correction*) (LYAPUSTIN et al., 2011; 2012a; 2012b). No entanto, mesmo com estas correções, as limitações da resolução espacial do sensor, combinadas com a alta cobertura de nuvens em ambientes tropicais, introduzem incertezas na análise de dados, especialmente na transição da escala regional para a local (PENG et al., 2017; WEIL et al., 2017; XIAO et al., 2006). Na Figura 2.1, um exemplo de dados do EVI com composição de 16 dias para o MODIS, porém sem a correção para efeitos bidirecionais, é apresentado. As diferentes passagens do sensor são aparentes na imagem, não representando um padrão de brilho natural esperado para o índice sobre florestas tropicais.

Figura 2.1 – Exemplo de recorte do produto MODIS (MAIAC) para o EVI somente para a correção atmosférica sem efeitos bidirecionais.



Fonte: Elaborado pelo autor.

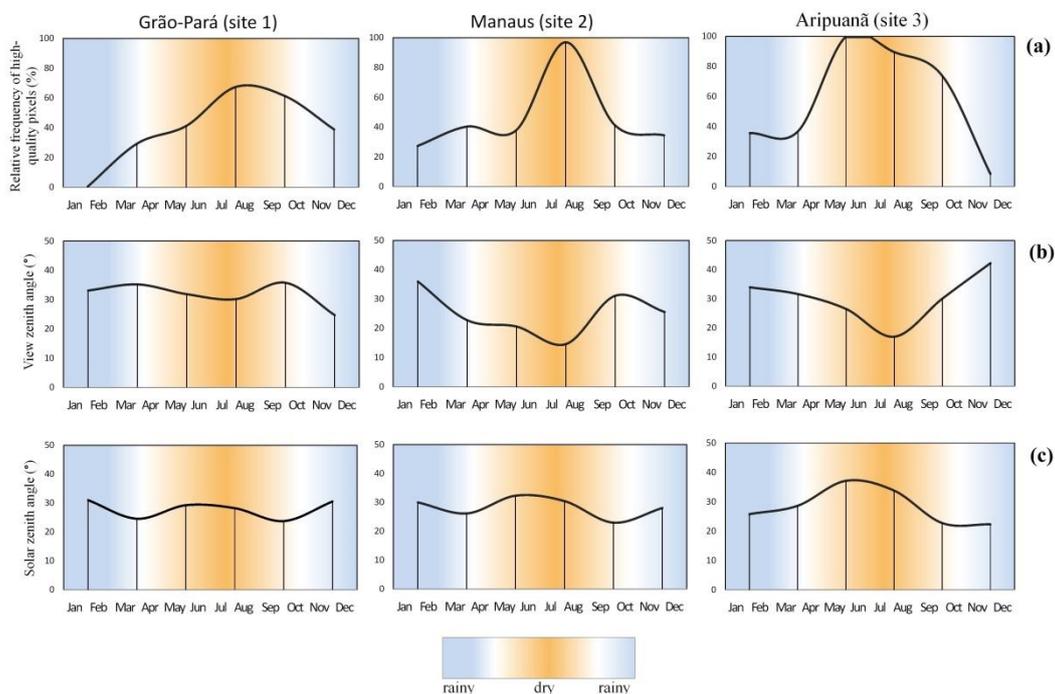
A definição temporal nos estudos de fenologia é característica-chave para a compreensão dos fenômenos estudados. Em virtude da alta cobertura de nuvens na estação chuvosa na Amazônia e do uso de dados satelitais, frequentemente, são estudados os períodos de seca. Em algumas regiões, entretanto, a cobertura de nuvens persiste mesmo na estação seca, como no norte do bioma (PETRI et al., 2019). Em função desses fatores, o estabelecimento de métricas fenológicas é prejudicado, já que a análise de séries temporais de alta qualidade radiométrica com IVs nem sempre é possível. Além disso, comparado com a vegetação de Cerrado, o sinal fenológico capturado pelos satélites sobre as florestas sempre verde da Amazônia possui pouca variação quando observada em escala de resolução espacial moderada a grosseira, como a do MODIS. Assim, é raro um ciclo sazonal completo, com presença de observações de alta qualidade radiométrica ao longo de sua série temporal, devido às condições adversas de observação do MODIS. Nesse sentido, estudos de fenologia por satélites na Amazônia, em escala regional, onde são utilizadas métricas fenológicas por produtos ou processamento de dados orbitais, são escassos (SILVA et al., 2017). O uso de índices de vegetação para medir a resposta direta do dossel à eventos da sazonalidade consiste no método mais utilizado, o que tem gerado

discussões profundas na literatura sobre a sua eficácia e os problemas enfrentados sobre as condições de observação de florestas tropicais (PETRI; GALVÃO, 2019; MOURA et al., 2017).

As principais discussões sobre a aplicação de índices de vegetação na Amazônia iniciaram após Saleska et al. (2007) observarem um aumento no verdejamento do dossel detectado pelo EVI durante a seca severa de 2005. Este resultado foi seguido por contestações e discussões sobre suas possíveis causas, uma vez que o verdejamento generalizado da vegetação amazônica durante o período de máximo déficit hídrico, mas também de intensa insolação, foi inesperado. Xu et al. (2011), estudando a seca de 2010, obtiveram resultados contraditórios em relação ao verdejamento do dossel. De acordo com outros estudos constantes na literatura, este verdejamento poderia estar relacionado ao brotamento de folhas novas (*leaf flush*), mudanças no índice de área foliar (IAF) em folhas jovens e maduras, modificações na estrutura do dossel decorrentes do evento de seca e variações no conteúdo de água das folhas (ANDERSON et al., 2010; BRANDO et al., 2010; FROLKLING et al., 2011; MYNENI et al., 2007).

Contudo, Galvão et al. (2011; 2013), Moura et al. (2012) e Morton et al. (2014) demonstraram que os efeitos provindos da geometria de aquisição – iluminação e visada – possuem forte influência sobre o EVI e o infravermelho próximo, região espectral à qual o índice é altamente dependente. Em decorrência disso, a própria variação sazonal da iluminação solar e sua relação com a seleção de pixels com ângulo de observação acentuado influenciam o comportamento do EVI no final da estação seca na Amazônia (Figura 2.2). A correção atmosférica e de efeitos bidirecionais, fundamental para o uso de dados MODIS, também foi discutida como fator relevante nessas observações. Os métodos tradicionais utilizados não apresentavam a eficiência necessária para que estudos de florestas tropicais e com um índice de vegetação sensível aos efeitos bidirecionais fossem aplicados. O MAIAC (*Multi-Angle Implementation of Atmospheric Correction*), proposto por Lyapustin et al. (2011a; 2011b; 2012) e aplicado em estudos por Hilker et al. (2017), Moura et al. (2017) e Petri e Galvão (2019), dentre outros, foi então discutido como uma alternativa de eficiência satisfatória para uso na Amazônia.

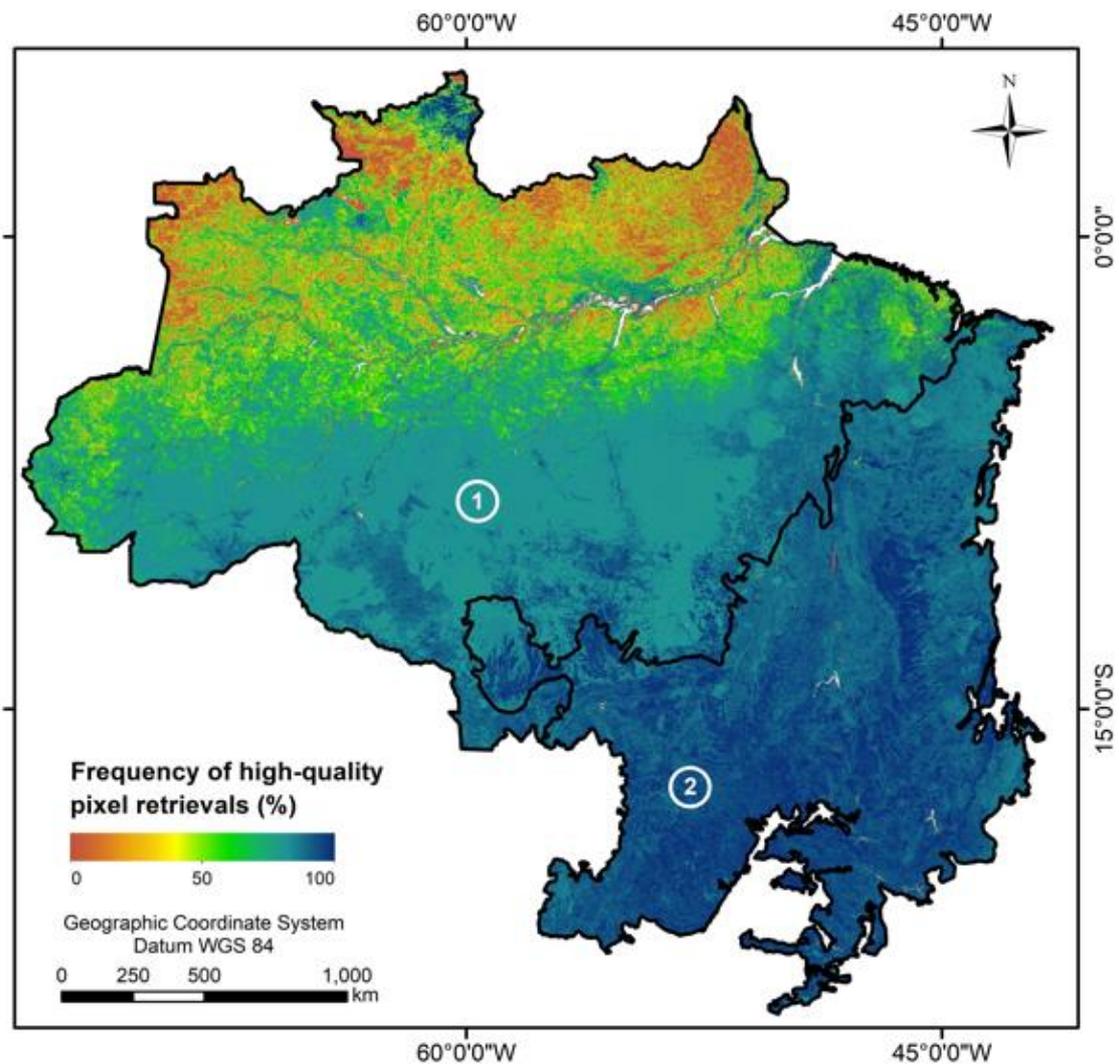
Figura 2.2 - Frequência relativa de pixels de alta qualidade, ângulo zenital de visada e ângulo zenital solar para áreas no norte (site 1), centro (site 2) e sul (site 3) da Amazônia.



Fonte: Petri e Galvão (2019).

Mesmo com a aplicação do MAIAC, os resultados apontaram para a persistência de um comportamento de verdejamento ao final da estação seca na Amazônia pelo EVI. Entretanto, a magnitude deste verdejamento foi reduzida em mais de 60% quando comparado com dados não corrigidos para o BRDF (PETRI; GALVÃO, 2019). As variações de EVI do início para o final da estação seca foram da ordem de 0.04. Parte deste efeito neste sinal residual pode estar relacionado com o processo de seleção de pixels ou correções imprecisas de dados. A Figura 2.3 apresenta a frequência de uso de pixels de alta qualidade para o produto MAIAC no mês de junho, entre 2000 e 2014. A seleção de pixels se torna problemática em áreas ao norte da Amazônia, onde a cobertura de nuvens é mais persistente mesmo durante a estação seca.

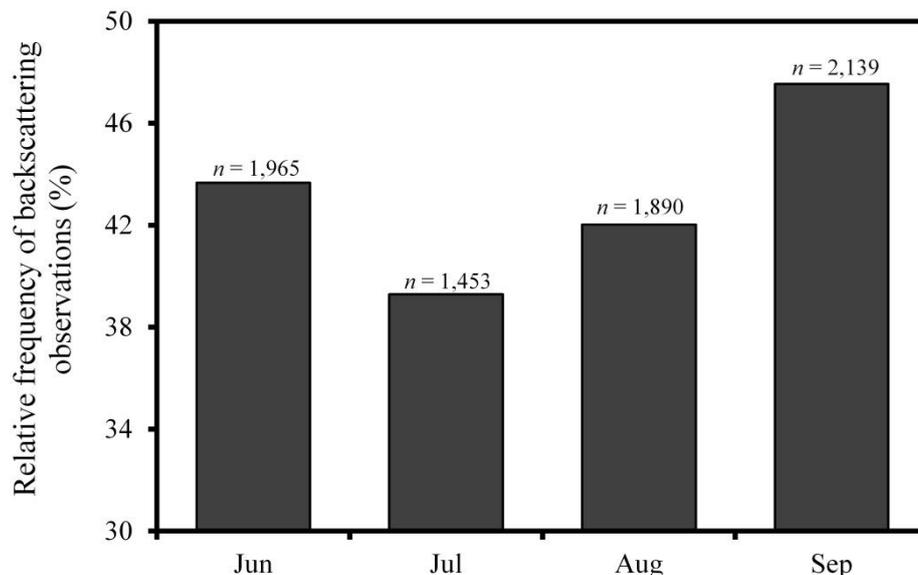
Figura 2.3 - Frequência relativa de observações de pixels de alta qualidade selecionados no produto MAIAC para a Amazônia em junho (2000-2014).



Fonte: Adaptado de Petri et al. (2019).

Como consequência, a seleção de pixels em produtos MODIS possui a tendência de selecionar observações em retro-espalhamento, com maior valor de reflectância (Figura 2.4).

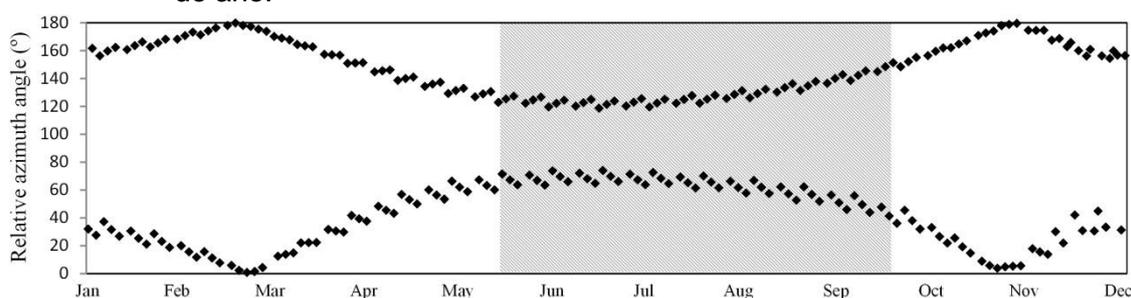
Figura 2.4 - Frequência relativa de observações em retroespalhamento para a Amazônia.



Fonte: Petri e Galvão (2019).

Soma-se a isso, a tendência da direção de visada das observações do MODIS no final da estação seca é a de  $140^\circ$  e  $40^\circ$  de ângulo azimutal relativo (Figura 2.5). No caso de dados MODIS (MAIAC), o ângulo azimutal relativo acima de  $90^\circ$  indica a presença predominante de observações em retroespalhamento.

Figura 2.5 - Ângulo azimutal relativo de observações do MODIS na Amazônia ao longo do ano.

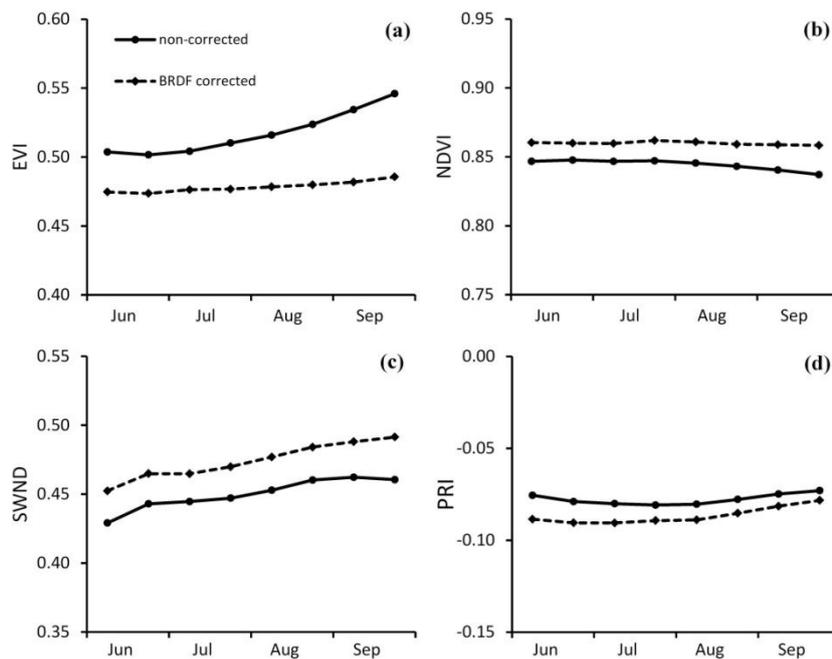


Fonte: Petri e Galvão (2019).

A discussão do verdejamento das florestas tropicais da Amazônia no final da estação seca pelo EVI, portanto, reside no fato de que grande parte do sinal observado é explicado por fatores relacionados à geometria de iluminação e observação do MODIS. Entretanto, quando estes efeitos são em princípio removidos, um aumento residual do EVI, muito menos significativo do que o

observado em dados não corrigidos para os efeitos bidirecionais, ainda pode ser observado. Isso ocorre mesmo após a correção pelo MAIAC dos efeitos atmosféricos e bidirecionais. Resíduos do processo de correção BRDF e fatores biofísicos podem estar relacionados a isso, porém com impacto prático muito menor do que o apontado por Saleska et al. (2007). A Figura 2.6 apresenta uma comparação entre as curvas corrigidas e não corrigidas para o EVI, principal índice das discussões sobre fenologia da Amazônia por satélites na literatura, e NDVI, SWND (*Short-Wave Normalized Difference*, índice normalizado entre as bandas 6 e 7 do MODIS) e PRI (*Photochemical Reflectance Index*), evidenciando o alto impacto dos efeitos bidirecionais sobre o EVI e seu grau cumulativo em direção ao final da estação seca na Amazônia.

Figura 2.6 - EVI, NDVI, SWND e PRI corrigidos e não corrigidos para efeitos bidirecionais pelo MAIAC ao longo da estação seca na Amazônia (2000-2014).



Fonte: Petri e Galvão (2019).

Recentemente, Ma et al. (2020) encontraram resultados significativos na dependência dos IVs EVI e NDVI ao AZS. Embora com base em fitofisionomias diferentes das florestas tropicais da Amazônia (o estudo foi conduzido na Austrália), os resultados encontrados destacam que tais efeitos foram significativos, com maior destaque para o NDVI para os locais estudados. A

diferença entre o NDVI e EVI, contrária à reportada para a Amazônia, é justificada pelos autores como a provável saturação constante do NDVI quando aplicado sobre florestas tropicais sempre verdes. De qualquer modo, é destacada a importância da investigação dos efeitos de iluminação solar causados pela sazonalidade em diferentes latitudes e, principalmente, seu efeito observado nas diversas fitofisionomias em um aspecto físico.

## **2.2 Secas na Amazônia e o cálculo do déficit hídrico acumulado**

Nas últimas décadas, tem sido observado o aumento generalizado na frequência de eventos de secas severas na Amazônia (SALESKA et al., 2007; SILVEIRA et al., 2020). Conforme comentado anteriormente, 2005 e 2010 foram anos de seca severa que se estabeleceram como base para a discussão em relação ao comportamento interanual do EVI. Quando comparado com a seca de 2005, a seca de 2010 foi mais abrangente na Amazônia. Após 2010, outros eventos de seca foram detectados a partir de dados satelitais, corroborando a eventos observados localmente ou em todo o bioma. Entre 2015 e 2016, um novo evento de seca severa se espalhou pelo bioma, dando importância ao uso de ferramentas para a medição do déficit hídrico acumulado regionalmente ou em todo o bioma (SILVEIRA et al., 2020). O MCWD (*Mean Cumulative Water Deficit*) é um exemplo de produto desenvolvido e utilizado para a mensuração do déficit hídrico acumulado, baseado em dados do CHIRPS (*Rainfall Estimates from Rain Gauge and Satellite Observations*), produto destinado ao monitoramento do clima e da distribuição de chuvas (SILVA JUNIOR et al., 2019; SILVA JUNIOR et al., 2021; FUNK et al., 2015). Este tipo de produto é especialmente aplicável na Amazônia para compreender o potencial impacto da seca na vegetação, as respostas fenológicas do dossel e as suas consequências sistêmicas para o bioma.

O MCWD é calculado a partir de dados de precipitação de diferentes fontes de dados climáticos históricos obtidos por satélite considerando o déficit hídrico anual acumulado para cada célula (0.05 graus), em uma série temporal de 1981 a 2020 e com abrangência espacial de 50°S a 50°N. Em função dessas características, esse produto possui amplo potencial para aplicação em estudos que levam em consideração a dinâmica de secas no bioma. Um exemplo de aplicação é o estudo desenvolvido por Silveira et al. (2020), que

encontraram no MCWD uma resposta de déficit hídrico regionalmente localizado no bioma para o ano de 2019, discordante espacialmente das porções que concentraram os eventos de fogo. Como resultado, não foi possível estabelecer uma relação direta da seca como causadora natural dos eventos de fogo ocorridos em 2019. Em estudos fenológicos com foco na resposta de dados orbitais à sazonalidade da vegetação e à influência da geometria de iluminação, é fundamental a compreensão prévia do perfil de disponibilidade hídrica para o período estudado. Em se tratando de um ano de seca acima da média, por exemplo, pode não ser possível estabelecer conclusões relevantes sobre a resposta biofísica e os artefatos originados por efeitos BRDF em IVs uma vez que parte do comportamento sazonal estará correlacionado com a magnitude do evento de seca em si.

### **2.3 Pré-processamento de imagens para estudos da vegetação com séries temporais**

Os algoritmos para o pré-processamento de imagens de sensoriamento remoto que visam o estudo da vegetação podem ser descritos como ferramentas de uso essencial no ajuste de séries temporais de dados ambientais para a extração métricas espectrais, espaciais ou mesmo de datas relacionadas às transições de fase fenológica, relacionadas à sazonalidade da vegetação. Serão apresentados alguns procedimentos básicos de filtragem e preenchimento de séries temporais, comumente adotados antes de aplicação das análises em si.

#### **2.3.1 Filtragem de dados e preenchimento de séries temporais**

Técnicas de filtragem e preenchimento de dados são necessárias para que uma série temporal tenha comportamento consistente com a extração de métricas fenológicas de forma intra- e interanual com maior precisão. A filtragem de dados busca remover possíveis *outliers* e orientar a sucessão de datas entre imagens e/ou amostras de dados, enquanto o preenchimento de séries complementa a filtragem ao preencher dados faltantes, tanto no caso de *outliers* quanto no caso da ausência completa de revisita em determinado momento da série temporal (SAKAMOTO et al., 2010). A seguir são detalhados

os principais métodos de filtragem e preenchimento utilizados em séries temporais.

### 2.3.1.1 Interpolação linear

A interpolação linear simples funciona com o propósito de preencher e suavizar *outliers* em determinada série temporal (BENDINI, 2018). A presença de nuvens em determinada série temporal, seja ela espaçada regularmente ou não, pode ser suprida pela substituição dos valores de toda a imagem, ou com uso de uma amostra da mesma. O mesmo funciona também na hipótese de valores nulos presentes na imagem. A técnica pode ser matematicamente descrita pela Equação 2.1:

$$X_t = \frac{X_{t-1} + X_{t+1}}{2} \quad (2.1)$$

Onde  $X_t$  representa uma observação da série temporal;  $X_{t-1}$  representa uma observação em  $t-1$ ; e  $X_{t+1}$  representa uma observação em  $t+1$  (BENDINI, 2018).

É importante frisar que a aplicação da substituição de dados faltantes ou *outliers* pela aplicação de uma interpolação linear simples está, em grande parte dos casos, associada a um algoritmo mais complexo de filtragem e suavização de séries temporais, sejam elas regularmente espaçadas ou não.

### 2.3.1.2 Algoritmos de máscara de nuvens

Para a filtragem de nuvens em uma série temporal, existe a possibilidade de adoção de diversas abordagens individuais. A utilização de algoritmos automatizados ou semi-automatizados para mascarar e filtrar nuvens torna o procedimento mais rápido e eficiente ao tratar séries temporais longas e com um grande volume de dados. Assim, o tratamento de máscaras de nuvens passa a ser uma abordagem de produtos cientificamente validados para determinadas aplicações (HENDERSON-SELLERS, 1982; STOWE et al., 1991; SIMPSON; GOBALT, 1996).

Algoritmos baseados em objetos para filtragem de nuvens buscam a identificação de nuvens e sombras de nuvens por atributos físicos como, por

exemplo, no *Fmask* (ZHU; WOODCOCK, 2015; BENDINI, 2018), onde a busca definirá camadas de nuvens e/ou sombras de nuvens a serem utilizadas como máscaras. Métodos como esse funcionam de forma eficaz na identificação da posição de nuvens em uma imagem, ao contrário de algoritmos geralmente utilizados apenas para a identificação de porcentagem de nuvens na cena, como o *Cloud Cover Assessment* (ACCA) (IRISH, 2000; IRISH et al., 2006) usado para a série Landsat. Os desafios atribuídos a este tipo de abordagem se encontram na transparência de nuvens e limiares entre nuvem, sombra e outros elementos quando utilizados em imagens de alta resolução espacial (ZHU; WOODCOCK, 2015; SAUNDERS; KRIEBEL, 1998).

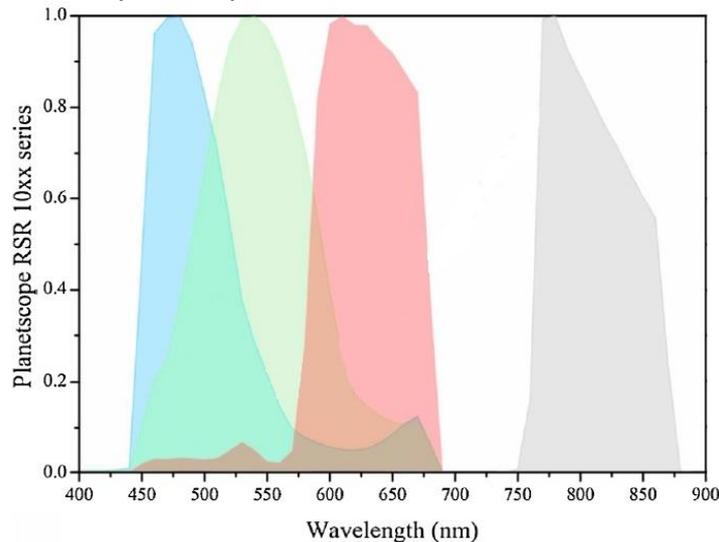
Por outro lado, muitas constelações de satélites de alta resolução espacial não possuem bandas que cobrem regiões espectrais de maior comprimento de onda, inviabilizando métodos tradicionais e algumas abordagens por objeto. Malladi et al. (2018) utilizam métricas texturais, baseado em classificadores de redes neurais, como solução para detecção de nuvens em sensores que cobrem o espectro visível e infravermelho próximo, cada vez mais comuns no contexto de constelações de alta resolução espacial e VANTs (Veículos Aéreos Não Tripulados) (BERRA et al., 2019).

#### **2.4 Constelações de satélites PS e séries temporais**

A constelação de satélites PlanetScope (PS), em operação desde 2016, é uma rede de múltiplos satélites de pequeno porte operando em grupos de órbitas. Vale lembrar que este é um conjunto de dados privados, pertencentes à empresa Planet. O caráter de operação de múltiplos sensores é a principal característica dos dados gerados por esta constelação, com destaque para o *Planet Surface Reflectance Product*. O produto oferece dados de aquisição próxima ao nadir ( $<5^\circ$ ), gerados com uso do modelo de transferência radiativa 6S, que efetiva a correção atmosférica e a conversão para reflectância de superfície, usando também dados auxiliares MODIS para estimativa de visibilidade. O tempo de revisita é diário. Contudo, na Amazônia, a disponibilidade diária de imagens sem cobertura de nuvens nem sempre é possível, principalmente na estação chuvosa.

A resolução espacial nominal dos dados PS é 3,7 m, caracterizando-os como de alta resolução espacial. Espectralmente, o produto PS oferece três bandas na região do visível e uma na região do infravermelho próximo. A Figura 2.7 apresenta a função de resposta espectral relativa das bandas PS (BREUNIG et al., 2020).

Figura 2.7 - Resposta espectral relativa das bandas dos sensores PS.



Fonte: Adaptado de Breunig et al. (2020).

Recentemente, a partir de 2020, a Planet introduziu novas gerações de constelações de satélites, nomeadas como *SuperDoves*, a fim de ampliar a cobertura espectral para oito bandas mais estreitas, porém mantendo a alta resolução espacial das gerações iniciais. Dessa forma, a empresa seguiu produzindo séries temporais inter-relacionadas para produtos que seguem com melhoria contínua em sua qualidade radiométrica e espacial. Além disso, novos algoritmos para filtragem de nuvens e correção atmosférica foram introduzidos nos dados dessas novas gerações. Infelizmente, porém, os anos iniciais representados pelos produtos pioneiros são cobertos apenas pelas quatro bandas espectrais acima descritas, que contém significativa sobreposição em sua função de resposta.

## **2.5 Técnicas de análise de imagens de sensoriamento remoto para florestas tropicais**

Em estudos relacionados à fenologia da vegetação de florestas tropicais, são frequentes as abordagens analíticas a partir de dados provenientes de imagens de sensoriamento remoto orbitais. Nesse contexto, destacam-se os grupos de análises espectrais e espaciais. Enquanto o primeiro grupo avalia o comportamento de pixels em seu conteúdo fisicamente traduzido pela reflectância, o segundo introduz o espaço na abordagem por meio de avaliações da relação entre pixels e sua vizinhança.

### **2.5.1 Atributos espectrais**

Os atributos espectrais podem ser traduzidos pela reflectância medida no pixel, índices de vegetação (IVs) tradicionalmente utilizados, análises de componentes principais ou mesmo outras operações aritméticas sobre bandas que não constituem um IV. Com o propósito de detectar distúrbios em savanas no Brasil, Souza et al. (2021) utilizaram séries temporais de sete IVs derivados de dados Landsat, entre 2017 e 2019, além de um algoritmo de detecção de alteração no contínuo (CCDC). Os resultados mostraram que a combinação de IVs aumentou a acurácia em 51,2% para o *Green-Red Normalized Difference* (GRND) e 65,9% para o *Normalized Burn Ratio* (NBR2), para 71,2%. Por sua vez, Petri et al. (2019) utilizaram a análise por componentes principais (ACP) para avaliar o incremento do brilho de imagens MODIS durante a estação seca na Amazônia. Os resultados mostraram que o brilho foi representado pela primeira componente da análise, aumentando significativamente entre julho e outubro. A seguir, serão apresentados, especificamente, tópicos sobre o Modelo Linear de Mistura Espectral (MLME) e da ACP.

#### **2.5.1.1 Modelo Linear de Mistura Espectral**

A aplicação de modelos lineares de mistura espectral (MLME) ocorre a partir da seleção de *endmembers*, que são curvas espectrais simplificadas por um pixel, ou um conjunto de pixels, que são representativas do comportamento da classe desejada (SHIMABUKURO et al., 1998). Ping et al. (2023) utilizaram imagens PS e Landsat para investigar a ocorrência de efeitos de *blowdown* na Amazônia central, além de comparar as respostas e composição de séries

temporais a partir dos dois sensores. Os métodos incluíram o uso de um modelo de mistura espectral com três componentes: vegetação verde, vegetação não fotossinteticamente ativa e sombra. Os resultados indicaram uma melhor composição de séries temporais a partir da base de dados PS, permitindo uma caracterização mais precisa dos eventos. Ao todo, 45 eventos de *blowdown* foram identificados e analisados.

O MLME, de forma resumida, utilizará as componentes determinadas pelos *endmembers* para criar as frações explicadas por cada componente. Ou seja, novas imagens serão criadas para cada componente e o valor do pixel de cada banda equivalerá à representatividade relativa da componente em relação à entrada original. No modelo linear adotado para o MLME, o modelo matemático será expresso por:

$$p(\gamma) = \sum_{i=1}^N f_i * R_i(\gamma) + \epsilon(\gamma) \quad (2.2)$$

Onde  $p(\gamma)$  representa a reflectância observada,  $N$  representa o número de componentes na cena,  $f_i$  representa a fração coberta pela  $i$ -ésima componente,  $R_i(\gamma)$  representa a reflectância da  $i$ -ésima componente, e  $\epsilon(\gamma)$  representa o erro da observação.

Os *endmembers* podem ser selecionados manualmente, a partir do estabelecimento de curvas sintéticas ou mesmo em procedimentos automatizados, como o *Sequential Maximum Angle Convex Cone* (SMACC) (GRUNINGER et al., 2004). O SMACC, originalmente concebido para o uso com dados hiperespectrais calibrados, é capaz de selecionar um dado conjunto de *endmembers* de forma rápida. O método do cone convexo utilizado consiste minimização de resíduos a partir de pontos extremos utilizados na determinação do cone para a definição do primeiro *endmember*. A partir de então, acontece a aplicação de uma projeção oblíqua ao cone existente para derivar o próximo *endmember*, que causa a ampliação do cone. O processo se repete até que a projeção obtenha um *endmember* já existente no cone, consideradas as tolerâncias imputadas, ou até a obtenção do número de *endmembers* desejados (GRUNINGER et al., 2004).

Matematicamente, o SMACC pode ser definido pela seguinte expansão de um cone convexo:

$$H(c, i) = \sum_k^N R(c, k) A(k, j) \quad (2.3)$$

Onde  $H$  é o *endmember*,  $i$  é o índice do pixel,  $j$  e  $k$  são os índices do *endmember* de 1 até o tamanho da expansão  $N$ ,  $R$  é a matrix que contém o espectro do *endmember* em colunas,  $c$  é o índice espectral do canal, e  $A$  é a matriz que contém a contribuição fracional (abundância) de cada *endmember*  $j$  em cada *endmember*  $k$  para cada pixel.

O MLME é uma técnica amplamente difundida, por exemplo, em produtos e análises com foco na detecção do desmatamento e fogo em florestas tropicais (ANDERSON et al., 2005; ASNER et al., 2004; MONTEIRO et al., 2003; SOUZA; BARRETO, 2000; SOUZA et al., 2005, 2003, 2013). Projetos de detecção e quantificação do desmatamento como o PRODES também se utilizam do MLME para a separação de frações antes da etapa final de classificação de polígonos (CÂMARA et al., 2013).

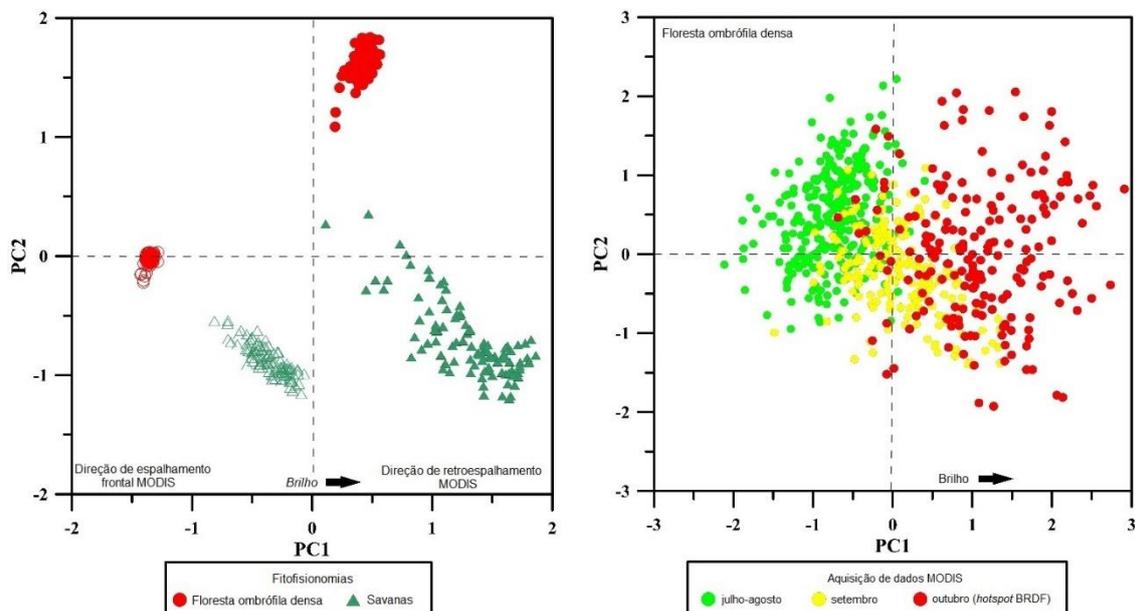
### **2.5.1.2 Análise por Componentes Principais**

A ACP é um método focado na redução da dimensionalidade dos dados de entrada, obtendo como saída componentes que explicam a variância dos dados. As componentes não são correlacionadas entre si, significando em geral que cada componente poderá ser interpretada como uma variável que influencia o conjunto de dados de entrada. Por exemplo, as variáveis explicativas representadas por uma componente principal podem ser o brilho das imagens ou mesmo a mudança de cobertura da terra ao longo de um período de tempo. A técnica possui destaque, por conta da redução de dimensionalidade, principalmente por ser capaz de eliminar a correlação entre diferentes bandas espectrais, comuns em sensores multiespectrais e, principalmente, em constelações de satélites que possuem funções de resposta sobrepostas. As componentes principais são ordenadas em grau de explicação da variabilidade dos dados, onde a primeira componente principal é a que explica a maior e principal variação. Componentes podem ser plotadas em conjunto para se observar a variação conjunta de diferentes aspectos

obtidos pela análise, mas as correlações, como já comentado, não serão significativas. Plotes temporais, portanto, são comuns para a observação da evolução de uma componente.

Retomando o estudo de Petri et al. (2019) anteriormente citado pelo uso da ACP, pode-se observar que a análise foi empregada em duas diferentes finalidades: a avaliação do comportamento de diferentes fitofisionomias (Floresta ombrófila densa e Savanas) em diferentes direções de imageamento (espalhamento frontal e retroespalhamento) de dados MODIS não corrigidos para efeitos bidirecionais (Figura 2.8a); e a variação de brilho entre julho e outubro para Florestas ombrófilas densas. Na primeira análise, a primeira componente principal explicou a variação em brilho, e a combinação das duas primeiras componentes principais evidenciou a separação de grupos tanto em fitofisionomias quanto em direção de espalhamento. Na segunda análise, a primeira componente principal indicou, também, a variação no brilho, com aumento do mesmo em direção ao hotspot BRDF em outubro (Figura 2.8b). Combinados, os resultados evidenciaram a importante influência do brilho e suas variações ao longo da estação seca na Amazônia, e também a diferenciação do comportamento entre diferentes fitofisionomias e a direção de espalhamento em um conjunto de dados com alta influência direcional. Foram consideradas as primeiras 7 bandas do MODIS.

Figura 2.8 - ACP aplicada para dados MODIS em diferentes fitofisionomias e durante a estação seca na Amazônia.



Em (a) são apresentados os resultados das duas primeiras componentes principais para Floresta ombrófila densa e Savanas; em (b) são apresentadas as duas primeiras componentes principais para dados de florestas ombrófilas densas entre julho e outubro, com observação em retroespalhamento.

Fonte: Petri et al. (2019).

## 2.5.2 Atributos espaciais

Atributos espaciais extraídos de imagens orbitais são, frequentemente, medidas que descrevem a interação e relação de um pixel com a vizinhança. Individualmente, métricas de textura como a média, variância e contraste são bons indicativos de variação temporal na composição da cena, principalmente quando utilizadas em janelas móveis pequenas. A seguir, será detalhado o processo da análise de métricas GLCM.

### 2.5.2.1 Métricas GLCM

As métricas *Gray-Level Co-occurrence Matrix* (GLCM) compõem uma técnica útil para a caracterização de textura em imagens de satélite, sendo caracterizadas, em geral, pelas relações espaciais entre os pixels de uma imagem e seus vizinhos, em janelas espaciais definidas. Diferentes métricas podem ser calculadas utilizando o mesmo contexto espacial. Seu significado estrutural para as imagens poderá ser utilizado na compreensão de alterações

fenológicas, classificações, detecção de alterações em uso e cobertura da terra, etc. Simionato et al. (2021) utilizaram atributos texturais de imagens Sentinel-2 como parte de um modelo orientado a objeto (GEOBIA) para identificar mineração em florestas tropicais da Amazônia. Simões (2022), por sua vez, também utilizou atributos texturais, traduzidos em métricas GLCM, para a estimativa de biomassa em uma área de Cerrado no estado do Tocantins. Na sequência, algumas das principais métricas GLCM serão apresentadas (HALL-BEYER, 2017; HARALICK et al., 1973).

#### 2.5.2.1.1 Média

A média da textura é calculada a partir do valor médio dos pixels na janela representativa selecionada. Matematicamente, é expressa por:

$$\sum_{i,j=0}^{N-1} i(P_{i,j}) \quad (2.4)$$

Onde  $P_{i,j}$  representa a matriz de co-ocorrência, e  $i,j$  representam as posições na matriz.

#### 2.5.2.1.2 Variância

A média da textura é calculada a partir do valor da variância entre os pixels na janela representativa selecionada. Matematicamente, é expressa por:

$$\sum_{i,j=0}^{N-1} i P_{i,j} (i - ME)^2 \quad (2.5)$$

Onde  $P_{i,j}$  representa a matriz de co-ocorrência, e  $i,j$  representam as posições na matriz.

#### 2.5.2.1.3 Contraste

O contraste é uma métrica determinada pelas variações locais na janela selecionada. Quanto maior a variação dentro de uma janela, maior o valor de contraste atribuído ao pixel central. Matematicamente, pode ser expresso por:

$$\sum_{i,j=0}^{N-1} i P_{i,j} (i-j)^2 \quad (2.6)$$

Onde  $P_{i,j}$  representa a matriz de co-ocorrência, e  $i,j$  representam as posições na matriz.

#### 2.5.2.1.4 Correlação

A correlação é uma métrica que representa a dependência linear dos pixels na janela de interesse. Matematicamente, é expressa por:

$$\sum_{i,j=0}^{N-1} i P_{i,j} \left[ \frac{(i - \mu_i) - (j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (2.7)$$

Onde  $P_{i,j}$  representa a matriz de co-ocorrência,  $i,j$  representam as posições na matriz e  $\mu, \sigma$  representam a média e desvio padrão da matriz, respectivamente.

#### 2.5.2.1.5 Homogeneidade

A homogeneidade pode ser interpretada como uma métrica oposta ao contraste. Quando o contraste aumenta, a homogeneidade tende a reduzir, indicando que a janela analisada é menos homogênea. Matematicamente, pode ser expressa por:

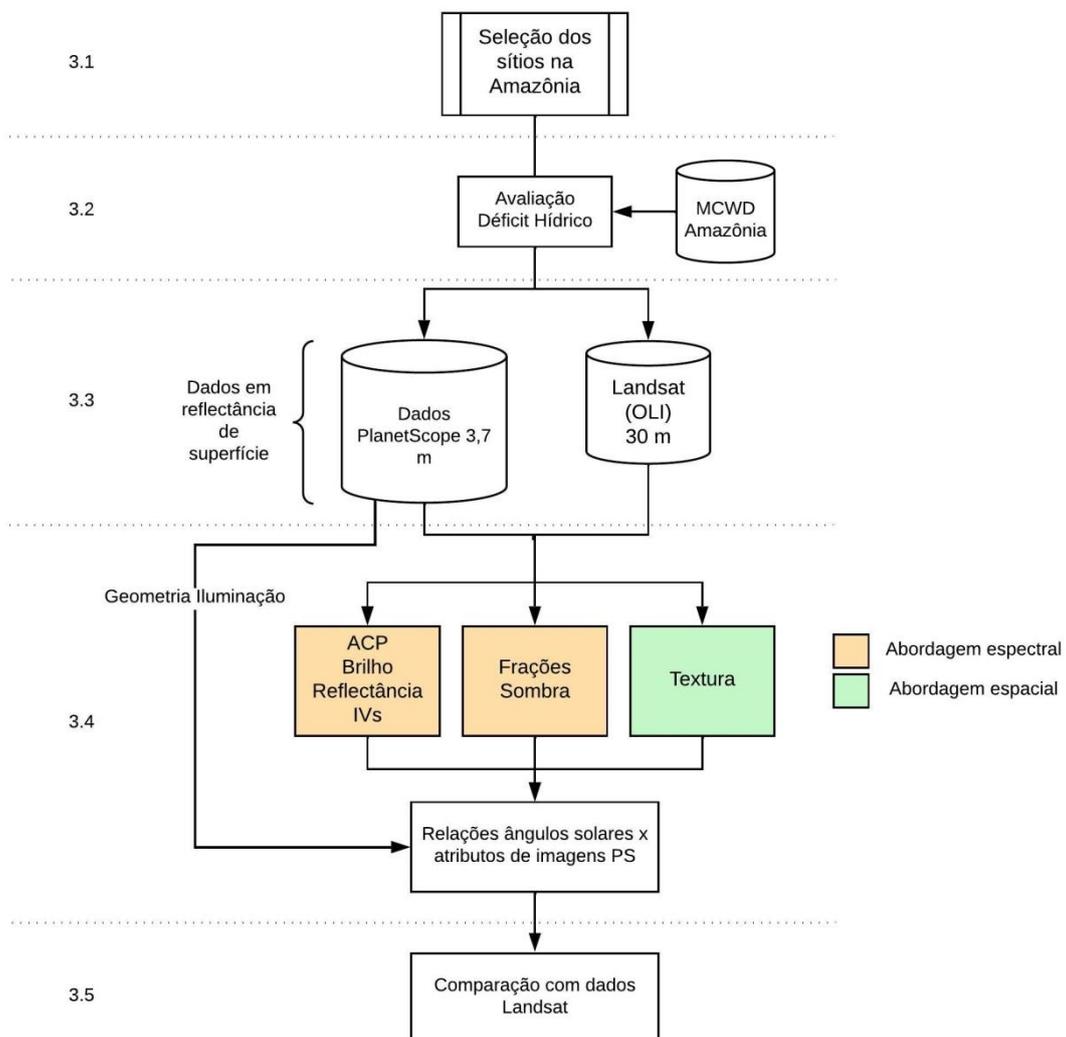
$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i-j)^2} \quad (2.8)$$

Onde  $P_{i,j}$  representa a matriz de co-ocorrência, e  $i,j$  representam as posições na matriz.

### 3 METODOLOGIA

A metodologia deste trabalho se divide em etapas de seleção de áreas de estudo com base em sua localização geográfica e características de disponibilidade hídrica, aquisição de dados de sensoriamento remoto e análises espectrais e espaciais para tais dados. A Figura 3.1 apresenta o fluxograma metodológico simplificado do trabalho.

Figura 3.1 - Fluxograma metodológico de seleção de áreas de estudo, aquisição de bases de dados e processos analíticos desenvolvidos no trabalho.

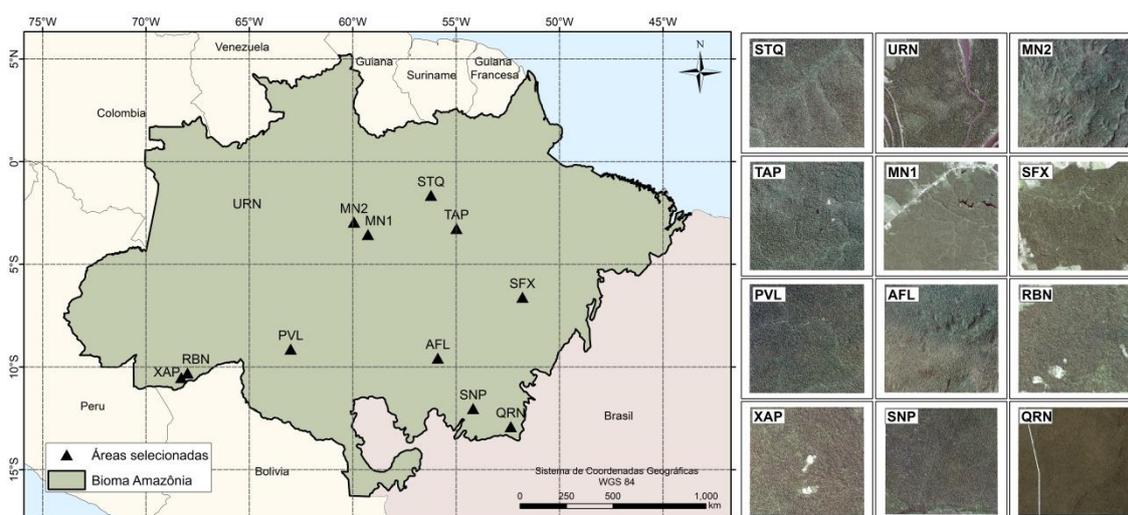


Fonte: Elaborado pelo autor.

### 3.1 Seleção das áreas de estudo

Para a realização deste trabalho foram selecionadas 12 áreas de estudo na Amazônia, com dimensões de 5 x 5 km, cobrindo diferentes latitudes do bioma (Figura 3.2). Seis áreas estão situadas na parte norte do bioma, até 7°S de latitude: Uarini (URN), Manaus-1 (MN1), Manaus-2 (MN2), Saracá-Taquera (STQ), São Félix do Xingu (SFX), e Tapajós (TAP). As outras seis áreas estão concentradas na região sul do bioma, próximo aos 10°S de latitude e correspondem a: Xapuri (XAP), Rio Branco (RBN), Porto Velho (PVL), Alta Floresta (AFL), Sinop (SNP), e Querência (QRN).

Figura 3.2 - Localização das 12 áreas de estudo (5 x 5 km) selecionadas para a análise de dados na Amazônia brasileira. À direita, as 12 áreas de estudo são apresentadas com composição verdadeira utilizando dados PS.



Fonte: Elaborado pelo autor.

As áreas selecionadas representam diferentes condições climáticas (Classes de Köppen Geiger Af, Am e Aw) (KOTTEK et al., 2006), tipos de solo (Ferrisolos, Acrissolos e Gleissolos) (QUESADA et al., 2011), biomassa (Almeida et al., 2019), altitude e altura média de dossel (Tabela 3.1). As áreas de estudo são predominantemente cobertas por florestas ombrófilas de terra firme (TFO). A precipitação anual média acumulada e a biomassa acima do solo (AGB) calculada nessas áreas, em geral, aumenta no sentido leste (p.ex., TAP e SFX) para oeste (p.ex., MN1 e MN2). Na região sul da Amazônia, SNP e QRN foram selecionadas para representar o ecótono entre florestas ombrófilas

e florestas sazonais, tendo a característica de florestas transicionais de terra firme. A altitude, entre as áreas de estudo, varia de 25,7 m (MN1) a 378,1 m (QRN). Medições de LiDAR (*Light Detection and Ranging*) aerotransportado indicam a altura média do dossel variando de 8,9 m (SFX) a 20,5 m (PVL) (Tabela 3.1).

Tabela 3.1 - Características principais das 12 áreas de estudo selecionadas na Amazônia brasileira. Os dados de solo são baseados em Quesada et al. (2011). A precipitação anual média e temperatura anual média foram derivadas do WorldClim v2 (Fick e Humans, 2017), enquanto que a biomassa média foi calculada por Almeida et al. (2019). A altitude local e a média de altura do dossel foram medidas por LiDAR aerotransportado. As abreviaturas para os tipos de floresta são: SFO (floresta ombrófila sazonalmente inundada), TFO (floresta ombrófila de terra firme), e TFT (floresta ombrófila de transição).

Área	Nome	Loc.	Lat (°)	Long (°)	Floresta	Solo	Clima	Altitude (m)	P.A.M. (mm. yr <sup>-1</sup> )	T.A.M. (°C)	B.M. (Mg. ha <sup>-1</sup> )	Altura Dossel (m)
STQ	Sacará-Taquera	Norte	-1.6	-56.2	TFO	Ferrissolos	Am	48.0	2400	26.8	-	19.7
URN	Uarini	Norte	-2.7	-65.1	SFO	Gleysolos	Af	36.7	3406	26.7	135.5	11.9
MN2	Manaus-2	Norte	-2.9	-59.9	TFO	Ferrissolos	Am	61.6	2356	26.4	283.0	19.7
TAP	Tapajós	Norte	-3.2	-54.9	TFO	Ferrissolos	Am	123.0	1848	25.8	289.9	13.9
MN1	Manaus-1	Norte	-3.5	-59.2	TFO	Acrissolos	Am	25.7	2293	25.8	306.7	12.6
SFX	São F. do Xingu	Norte	-6.6	-51.7	TFO	Acrissolos	Aw	289.1	1964	24.6	175.2	8.9
PVL	Porto Velho	Sul	-9.1	-63.0	TFO	Ferrissolos	Am	93.6	2388	25.2	229.2	20.5
AFL	Alta Floresta	Sul	-9.5	-55.8	TFO	Acrissolos	Aw	254.0	2216	26.6	222.1	17.5
RBN	Rio Branco	Sul	-10.2	-67.9	TFO	Acrissolos	Am	192.3	1896	25.3	-	11.7
XAP	Xapuri	Sul	-10.5	-68.2	TFO	Acrissolos	Am	211.4	1803	25.3	-	17.1
SNP	Sinop	Sul	-12.0	-54.1	TFT	Ferrissolos	Aw	320.0	1815	24.7	155.8	13.7
QRN	Querência	Sul	-12.9	-52.3	TFT	Ferrissolos	Aw	378.1	1745	25.0	-	12.5

Fonte: Elaborado pelo autor.

### **3.2 Avaliação do MCWD para as áreas de estudo**

O déficit hídrico máximo acumulado, do inglês *maximum cumulative water deficit* (MCWD) (ARAGÃO et al., 2007), é uma medida de estresse hídrico que geralmente segue um gradiente de leste para oeste na Amazônia (SILVA JUNIOR et al., 2021; SILVA JUNIOR et al., 2019; FUNK et al., 2015). Esse gradiente reflete a duração da estação seca, que é mais longa (4 a 5 meses) no leste da Amazônia (MOURA et al., 2015), e o volume total de chuvas na estação seca. Neste trabalho, utilizamos o MCWD para observar a dinâmica anual (entre 2017 e 2019) e histórica do regime de déficit hídrico acumulado na Amazônia, a fim de compreender, espacialmente, a distribuição dos dados apresentados. Para isso, espacializamos o MCWD para a Amazônia em sua série histórica de 1981 a 2020, e analisamos as médias do MCWD para cada área de estudo entre os anos de 2017 e 2019, foco deste trabalho. Com a observação dos resultados para o MCWD para cada área de estudo selecionada, o estudo do impacto da iluminação solar em imagens PS e Landsat, minimiza o efeito significativo do déficit hídrico em cenas individuais e compondo uma série temporal entre 2017 e 2019.

### **3.3 Obtenção de imagens de satélites**

Neste trabalho, foram selecionados dois conjuntos de imagens de satélites em reflectância de superfície: PlanetScope e Landsat. Enquanto as imagens PS representaram a principal base de dados para a avaliação de geometria de iluminação solar e análise de atributos espaciais e espectrais, as imagens Landsat tiveram caráter comparativo, reproduzindo as análises espectrais e espaciais para a observação comparativa dos resultados em um conjunto de dados consagrado na literatura, com resolução espacial mais esparsa e observação também ao nadir.

#### **3.3.1 Obtenção de imagens PlanetScope e sua geometria de aquisição**

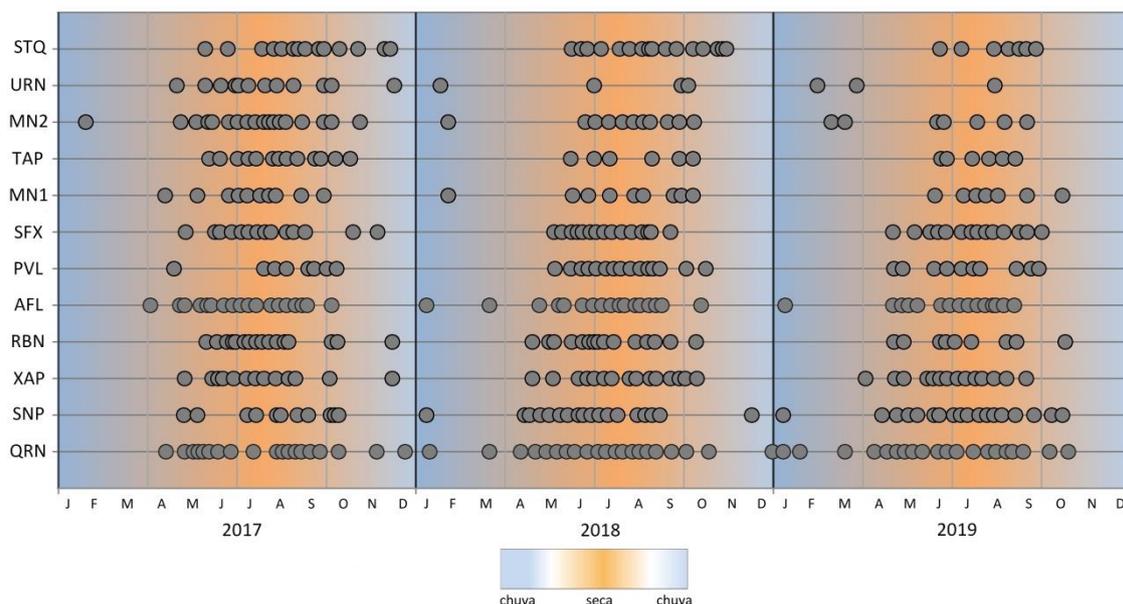
A constelação PlanetScope (PS), operando desde 2016, possui revisita diária para todo o globo (HOUBORGH; MCCABE, 2018). O horário local de passagem pela linha do equador é de aproximadamente 10:30 AM. As imagens

resultantes possuem resolução espacial de 3,7 m, enquanto o erro quadrático médio posicional é inferior a 10 m (CHENG et al., 2020; WU et al., 2021).

Para este estudo, foram utilizados dados de reflectância de superfície ortorretificados em nível 3B (PlanetScope OrthoScene), que inclui correção geométrica, atmosférica e radiométrica (PLANET LABS, 2020; WANG et al., 2020). Da base de dados PS, foram selecionadas 493 imagens livres de nuvens para cobrir as 12 áreas de estudo (tamanho 5 x 5 km) de 01/01/2017 a 31/12/2019. Nesse período, a maior parte dos dados PS esteve concentrada de abril a outubro de cada ano, devido às condições mais favoráveis de observação livre de nuvens na Amazônia (Figura 3.3). Durante o período representativo da estação seca (junho a setembro), a frequência de observações selecionadas se aproximou de 5 dias para a maior parte das áreas. Na estação chuvosa (outubro a maio), em função da forte cobertura de nuvens, têm-se uma redução na frequência de observações possíveis que ficou próxima a 20 dias. Entretanto, o foco do estudo é a estação seca amazônica, que representa o período de observação de interesse mais discutido na literatura.

Além disso, em virtude de atualizações e mudanças em especificações de sensores e produtos Planet ao longo do tempo, focou-se no uso apenas de sensores com órbita sol-síncrona. Assim, os sensores selecionados possuem quatro bandas espectrais: azul (464-517 nm); verde (547-585 nm); vermelho (650-682 nm); e NIR (846-888 nm). Ao fixar o tipo de órbita e as bandas espectrais, garantiu-se uma comparação válida de parâmetros de aquisição e de métricas espectrais e espaciais ao longo da série temporal construída com esses dados. Para quantificar e compreender a geometria de aquisição dos dados na estação seca, utilizou-se o ângulo zenital solar (AZS) e o ângulo azimutal solar (AAS) fornecidos nos metadados das imagens.

Figura 3.3 - Frequência de observações livres de nuvens entre 2017 e 2019 para cada uma das 12 áreas de estudo selecionadas na Amazônia.



As abreviaturas das áreas estão definidas na Tabela 3.1. O período selecionado como representativo da estação seca (Junho a Setembro) está destacado em laranja.

Fonte: Elaborado pelo autor.

### 3.3.2 Obtenção de imagens Landsat

De forma complementar, obteve-se um conjunto de imagens Operational Land Imager (OLI)/Landsat-8 para o período de 2017 a 2019, reproduzindo o mesmo tempo de observação do conjunto principal de dados PS. As imagens foram selecionadas a partir do produto de reflectância de superfície para dados livres de coberturas de nuvens na plataforma Google Earth Engine (GEE). O sensor OLI possui revisita de 16 dias com resolução espacial de 30 m. Ao todo, 243 imagens Landsat foram necessárias para cobrir as 12 áreas de estudo (Figura 3.2) no período analisado. A revisita de 16 dias, entretanto, somente foi efetivamente atingida para algumas áreas de estudo durante a estação seca devido a persistente cobertura de nuvens na Amazônia. É importante destacar que esse conjunto de imagens Landsat foi utilizado em termos comparativos, ou seja, ao longo das análises espectrais e espaciais descritas a seguir, a fim de reproduzir os resultados obtidos com dados PS com o uso de uma plataforma consolidada e historicamente utilizada no sensoriamento remoto.

Dessa forma, mesmo que em distintas resoluções espaciais, dados obtidos ao nadir puderam ser posicionados em perspectiva adotando as mesmas áreas de estudo, métodos de análise espacial e espectral, amostragens e representações gráficas. Vale ressaltar que não foi aplicada uma normalização da reflectância entre os dados PS e Landsat. Para a finalidade deste trabalho, a visualização das tendências em cada análise aplicada nos dados originais não seria aprimorada pela aproximação entre os dados em uma medida de escala mais próxima.

### **3.4 Análise de dados de atributos espaciais e espectrais**

A análise dos efeitos de iluminação solar durante a estação seca sobre atributos espectrais e espaciais, calculados a partir de dados PS e Landsat, foi dividida em três partes: (1) caracterização de variações em brilho da vegetação, reflectância e IVs durante a estação seca; (2) variações observadas na estação seca para métricas de textura (GLCM) das imagens; e (3) modificações sazonais na fração sombra calculada a partir de um MLME. Essas etapas metodológicas estão descritas a seguir.

Durante a análise de dados, considerou-se não apenas os anos individualmente, mas também a reflectância sazonal média calculada entre 2017 e 2019 para datas coincidentes na aquisição de imagens. Como mencionado anteriormente, esse período de três anos de imagens não foi impactado por secas severas (Tabela 4.1). Ao alternar as estratégias de amostragem dos dados, garantiu-se a confiabilidade do processo analítico para evitar incertezas associadas ao pré-processamento das imagens, como a correção atmosférica.

#### **3.4.1 Determinação de brilho e índices de vegetação (IVs) a partir de dados de refletância de superfície**

Para identificar a existência de padrões na estação seca para a iluminação solar em resposta às modificações na geometria de aquisição de imagens PS, adotou-se o ano de 2018 e aplicou-se uma análise por componentes principais (ACP) em cada área de estudo sobre os dados de reflectância medidos nesse

ano. A ACP é uma técnica que pode indicar valores de reflectância correlacionados entre bandas, reduzindo a dimensionalidade dos dados inseridos. Adicionalmente, é uma análise útil para detectar as bandas espectrais mais importantes em termos de variância dos dados (MOURA et al., 2017). A partir dessa análise, buscou-se observar eventuais variações na estação seca no brilho de florestas tropicais (uma proxy da reflectância média entre bandas), o qual em geral é associado à primeira componente principal (GALVÃO et al., 2019).

Utilizou-se a reflectância de superfície das quadro bandas multiespectrais do PS (azul, verde, vermelho e NIR), calculados a partir de amostras aleatórias de 100 pixels selecionados para cada área de estudo (em procedimento automatizado), como dados de entrada para a ACP. Os pixels selecionados foram amostrados aleatoriamente sobre a totalidade das imagens, apenas considerando uma máscara para uso da terra. Para esse propósito, selecionou-se uma data por mês (dia 15 de cada mês) para extrair observações PS entre junho e setembro do ano de 2018. A estratégia de seleção de datas específicas na estação seca para representar toda a série temporal PS foi necessária para facilitar o processamento e interpretação dos dados, além de se obter uma melhor representação gráfica dos resultados da ACP.

Da ACP, extraiu-se as primeiras duas componentes principais (CP1 e CP2), baseadas na matriz de correlação e nos autovalores maiores do que um. Geralmente, esses valores são responsáveis por mais de 90% da variância cumulativa dos dados. A contribuição de cada banda PS para explicar cada componente foi determinada pela análise dos autovetores. A medida de Kaiser-Meyer-Olkin (KMO) e o teste de esfericidade de Barlett foram utilizadas para testar a adequação da amostragem e a aplicabilidade dos dados para a redução de dimensionalidade (CERNY; KAISER, 1977). Também foram plotados os valores das duas primeiras componentes principais sem rotação para observar possíveis padrões de iluminação solar e seus efeitos na variação de brilho na vegetação ao longo da estação seca.

Para inspecionar a consistência dos resultados da ACP, estabeleceu-se um novo conjunto de amostras aleatórias, desta vez, composta por 1.000 pixels por cada área de estudo. Plotou-se, então, a reflectância de superfície média do período de 2017 a 2019 para cada uma das quatro bandas espectrais. Finalmente, calculou-se os dois índices de vegetação mais utilizados em estudos de sensoriamento remoto: o menos anisotrópico NDVI (Equação 3.1) e o mais anisotrópico EVI (Equação 3.2):

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (3.1)$$

$$EVI = 2.5 \times \left( \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + 6 \times [\rho_{Red}] - 7.5 \times [\rho_{Blue}] + 1} \right) \quad (3.2)$$

Onde  $\rho$  representa a reflectância de superfície das bandas do azul (*Blue*), vermelho (*Red*) e NIR dos satélites PS, respectivamente.

Em adição às curvas sazonais da estação seca para EVI e NDVI entre 2017 e 2019, também se calculou a correlação de tais IVs com o AZS e o AAS derivados das observações PS na estação seca, obtidas em datas centrais de cada mês (Figura 3.3). Além disso, replicou-se a análise das curvas sazonais de bandas e IVs para o conjunto de dados Landsat, utilizando a mesma amostragem de 1.000 pixels e calculando os IVs de acordo com as bandas adequadas para o novo conjunto de imagens.

### 3.4.2 Extração de métricas de textura GLCM

Efeitos de iluminação solar podem afetar a distribuição espacial dos tons de cinza ao longo dos pixels em imagens de alta resolução espacial, produzindo variações texturais em imagens PS adquiridas durante a estação seca na Amazônia. Portanto, análises texturais podem ser úteis para detectar variações localizadas em sombras projetadas pelo dossel e visualizadas pela constelação PS com a mudança de geometria de iluminação.

Neste trabalho, utilizou-se a análise de métricas de textura GLCM para descrever variações nos níveis de cinza nas imagens PS obtidas durante a

estação seca. Foi dado foco na análise da banda NIR (banda 4) dos dados PS. Para fins de comparação, foi replicada essa análise utilizando a banda do NIR do conjunto de dados Landsat-8 (banda 5). Comparado ao intervalo visível, a transmitância através do dossel é maior no NIR, trazendo mais informação sobre a estrutura da vegetação e as sombras projetadas pelo dossel capturadas pelos dados PS durante a estação seca. Seguindo as recomendações de Wood et al. (2012) e Zhou et al. (2017) para extrair com eficiência a informação de textura em imagens de alta resolução espacial, calculou-se oito métricas GLCM utilizando janelas móveis pequenas de 3 x 3 pixels. O tamanho pequeno das janelas pode realçar a heterogeneidade da vegetação e das sombras em imagens de alta resolução espacial observadas pela constelação, como reportado nos estudos citados com outros sensores. A quantização de escala de cinza foi de 64 bits e o deslocamento adotado da janela móvel foi de 1 x 1 pixel.

As oito métricas GLCM calculadas foram: média da textura (valor da média local da janela de processamento); variância (a variância local da janela de processamento); homogeneidade (a quantidade de similaridades dentro da janela de processamento); contraste (a quantidade de variação local entre valores de pixels da janela de processamento); dissimilaridade (variável inversamente relacionada à homogeneidade); entropia (grau de desordem dentro da imagem capturada pela janela de processamento); segundo momento (medida da uniformidade textural); e correlação (medida de dependência entre os valores de cinza na imagem). Maiores detalhes sobre cada métrica, incluindo suas equações, foram descritos por Haralick et al. (1973) e Zhou et al. (2017).

Diferenças estatísticas nas métricas de textura entre diferentes meses da estação seca foram avaliadas por testes de Tukey-Kramer, em um nível de significância de 1%. Para cada métrica de textura, testou-se as medianas, calculadas a partir das amostragens de 1.000 pixels entre junho e os meses subsequentes.

### 3.4.3 Variações em frações-sombra obtidas a partir de modelos de mistura espectral

Mudanças no brilho da vegetação detectadas pela ACP e as modificações texturais capturadas pelas métricas de textura são, também, análises que refletem o efeito da sombra presente no dossel. O MLME assume que a reflectância de cada pixel é uma combinação linear de valores de reflectância de *endmembers* (VAN DER MEER, 2004; SHIMABUKURO et al., 1998). Utilizando a técnica SMACC, selecionou-se um modelo simples de três *endmembers* composto por vegetação, solo/vegetação não-fotossinteticamente ativa (NPV) e sombra utilizando a reflectância de superfície das quatro bandas dos dados PS como dados de entrada para o MLME (Figura 3.4).

Da mesma maneira, dados Landsat das bandas 2, 3, 4 e 5 foram utilizados para reproduzir o MLME nesse conjunto de dados seguindo as mesmas etapas metodológicas. Especificamente, em ambos os casos (PS e Landsat), os *endmembers* foram selecionados automaticamente utilizando a técnica SMACC aplicada sobre os dados de reflectância da primeira data mensal selecionada em junho de 2018, considerando um único conjunto de *endmembers* para todas as áreas de estudo. Foi gerado um novo conjunto de *endmembers* para cada base de dados, procedimento necessário considerando as diferentes resoluções espectrais dos sensores. O SMACC utiliza a minimização de resíduos para encontrar pixels com o brilho contrastante na cena. O processo é repetido até atingir o número de *endmembers* solicitados pelo usuário, ou quando um *endmember* com características já existentes é capturado novamente, indicando a saturação do modelo (GRUNINGER et al., 2004). Neste trabalho, seguindo o procedimento proposto por Roberts et al. (1993), selecionou-se um espectro sintético de baixa reflectância como representante do *endmember* sombra (Figura 3.4). Utilizando o conjunto de três *endmembers* fixos a partir de junho de 2018, gerou-se e inspecionou-se as frações-sombra ao longo da estação seca de 2018 para identificar possíveis efeitos de iluminação solar produzidos por mudanças no AZS e no AAS durante a aquisição de imagens PS.

### **3.5 Comparação dos dados PS com dados Landsat**

Finalmente, foi realizada a comparação dos dados PS com os dados Landsat para as análises equivalentes de reflectância, IVs, métricas GLCM e mistura espectral. Como se tratam de dados com diferentes resoluções espaciais, espectrais, temporais e radiométricas, o processo comparativo não conteve etapas de cálculo de métricas ou correlações. Também não foi investigado, especificamente, o efeito de integração no pixel pela transição de escala espacial. O foco desta análise, portanto, foi a observação do comportamento das análises pareadas entre PS e Landsat, para as mesmas áreas de estudo, quanto à concordância de tendências sazonais durante a estação seca entre os conjuntos de dados. Vale destacar que não foi realizada a reamostragem de resolução espacial PS para a comparação com o Landsat. A observação das tendências em todas as análises aplicadas para os dados Landsat, utilizando as resoluções espaciais, espectrais e radiométricas originais foram um fator simplificador para validar padrões que podem ou não ser observados em diferentes tipos de dados e análises com base em sensores orbitais.

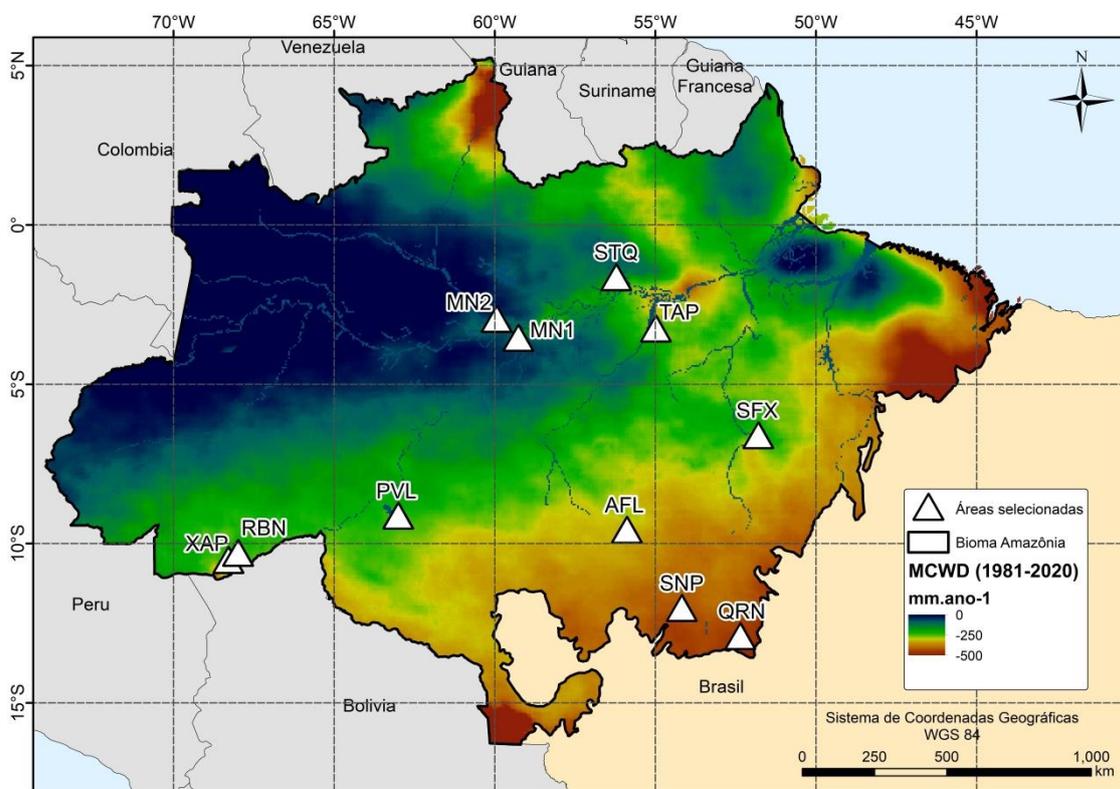
## **4 RESULTADOS**

Esta seção apresenta os resultados obtidos da avaliação da geometria de iluminação solar e de seus impactos, ao longo da estação seca da Amazônia, sobre a obtenção de atributos espectrais e espaciais da constelação PS. Comparações também são feitas com dados Landsat. Também é apresentada a análise do déficit hídrico no triênio 2017-2019, com base nos dados do MCWD, para caracterizar localmente a ausência de eventos de seca severa no período analisado. Embora tipos distintos de dados orbitais estejam presentes nas duas últimas análises, seu alinhamento nessa seção se deve, principalmente, às semelhanças metodológicas aplicadas, e não a uma comparação direta de transição de escalas espaciais entre esses conjuntos.

### **4.1 Déficit hídrico acumulado na Amazônia entre 2017 e 2019**

Ao observar a distribuição espacial do MCWD em sua série histórica (1981 a 2020), foi possível ampliar a compreensão sobre o regime de chuvas predominante em cada área de estudo analisada. A área de estudo URN, na Figura 4.1, representa o local com menor déficit hídrico histórico (-19.2 mm ano<sup>-1</sup>), enquanto que QRN, ao sul do bioma, possui maior déficit (-423.8 mm ano<sup>-1</sup>). As zonas de transição, representadas pelas áreas AFL, SFX e PVL, também merecem destaque, representando simultaneamente locais onde a estação seca passa a ser representada por um déficit hídrico transicional entre as regiões mais chuvosas e menos chuvosas para o período, possivelmente, configurando uma maior sazonalidade em índices de vegetação, reflectância e outras métricas.

Figura 4.1 - Déficit hídrico máximo acumulado (*Maximum cummulative water deficit - MCWD*) histórico (1981 – 2020) médio, representado em mm/ano, para o bioma Amazônia.



As áreas de estudo selecionadas aparecem em branco, representando diferentes regimes de déficit hídrico no bioma.

Fonte: Elaborado pelo autor.

A Tabela 4.1 apresenta as variações no déficit hídrico máximo acumulado entre 2017 a 2019, período de aquisição das imagens PS. O gradiente é expresso pelos valores mais baixos de MCWD observados ao longo dos anos para as áreas de estudo no leste da Amazônia (SNP, QRN, AFL e TAP), quando comparados às áreas localizadas na região oeste (MN1, MN2 e URN). Conforme descrito na literatura, no período de análise dos dados (2017 a 2019), não foram registrados eventos generalizados de seca severa na Amazônia (SILVEIRA et al., 2020). Houve apenas localmente o agravamento do déficit hídrico em 2019, ano de ocorrências intensas de fogo na Amazônia. Entretanto, esse fato não produziu mudanças significativas no MCWD para as áreas de estudo analisadas (Tabela 4.1).

Tabela 4.1 - Variações no déficit hídrico máximo acumulado (ou *maximum cumulative water deficit*, MCWD) nas áreas de estudo entre 2017 e 2019. Áreas localizadas ao leste (QRN, SNP, AFL e TAP) apresentaram maior estresse hídrico quando comparadas às áreas a oeste (MN1, MN2 e URN).

Área	Nome	2017	2018	2019
STQ	Sacará-Taquera	-229.3	-143.7	-137.4
URN	Uarini	-22.42	-18.99	-21.08
MN2	Manaus-2	-90.16	-95.86	-40.93
TAP	Tapajós	-314	-162.5	-77.94
MN1	Manaus-1	-101.5	-219.2	-80.8
SFX	São Felix do Xingu	-286	-199.6	-234.2
PVL	Porto Velho	-260.5	-177.7	-232.5
AFL	Alta Floresta	-395.6	-243	-310.5
RBN	Rio Branco	-216.2	-133.3	-159.3
XAP	Xapuri	-204.3	-128.1	-168.9
SNP	Sinop	-443.4	-335.5	-419.4
QRN	Querência	-467.6	-408.4	-444

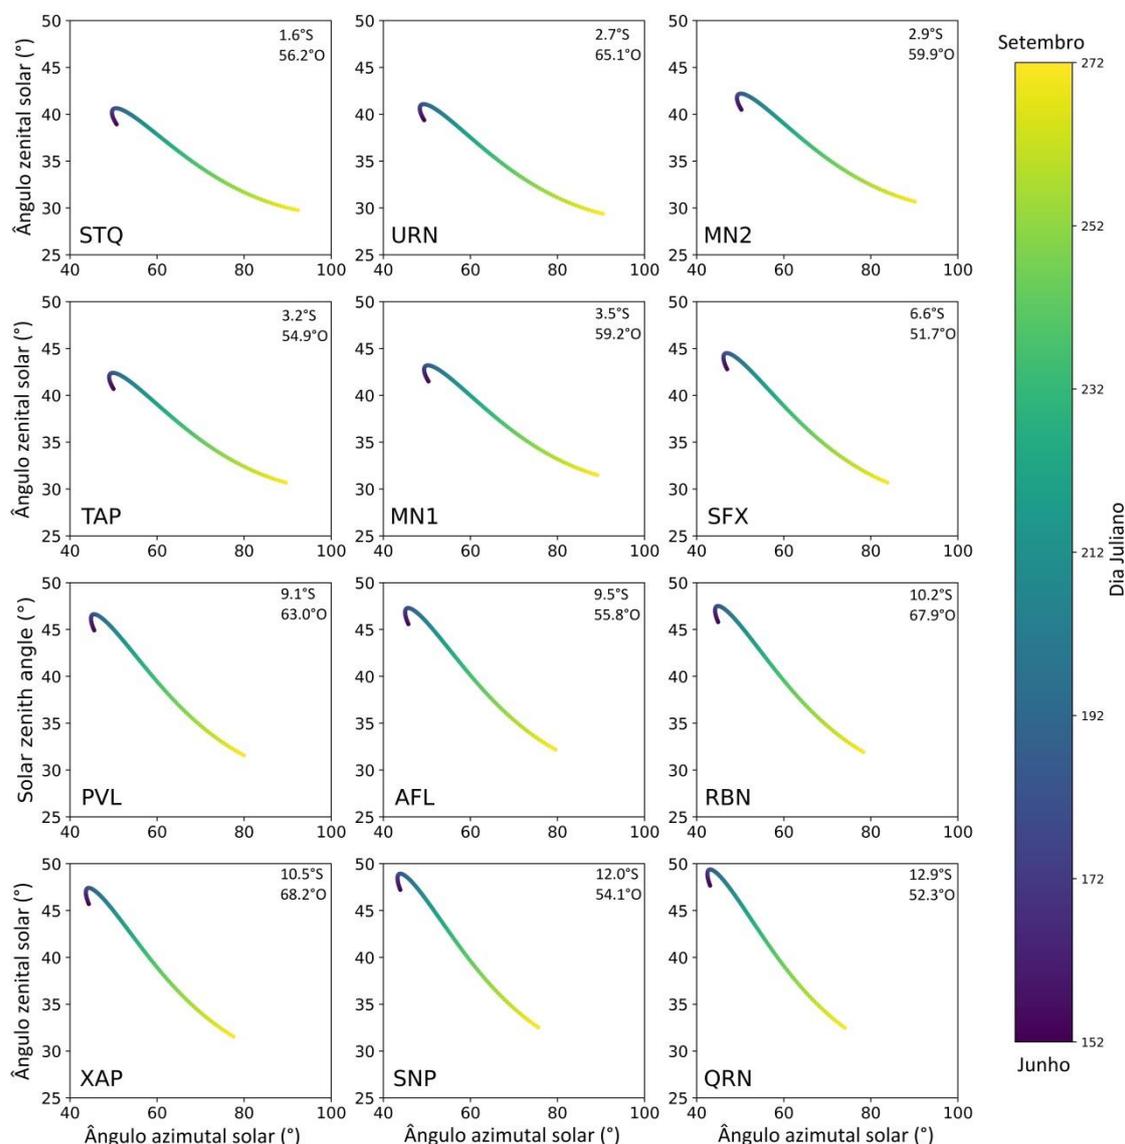
Fonte: Elaborado pelo autor.

## 4.2 Geometria de aquisição de imagens PlanetScope

A Figura 4.2 mostra o comportamento da geometria de aquisição das imagens PS nas 12 áreas de estudo ao longo da estação seca. Em contraste com os ângulos de visada intrínsecos dos dados PS, que não apresentam mudanças substanciais entre datas, a variabilidade nos ângulos solares acontece de forma mais drástica ao longo do tempo. Do início (junho) para o final (setembro) da estação seca da Amazônia, o AZS diminuiu e o AAS aumentou durante a aquisição de imagens PS nas 12 áreas selecionadas (Figura 4.2).

Esse comportamento na estação seca em ambos os ângulos solares contribuiu para o crescente espalhamento da energia incidente sobre o dossel, havendo redução da sombra projetada pelas copas das árvores vista pelos CubeSats em direção a setembro (final da estação seca). Entretanto, conforme indicado pelas linhas coloridas na Figura 4.2, a variação na geometria de aquisição dos dados PS do DOI 152 (junho) para o DOI 273 (setembro) diferiu por localização da área de estudo para o AZS e o AAS.

Figura 4.2 - Mudanças no ângulo zenital solar (AZS) e ângulo azimutal solar (AAS) durante a aquisição de imagens PlanetScope (PS) do início (DOI 152) para o final (DOI 272) da estação seca na Amazônia.



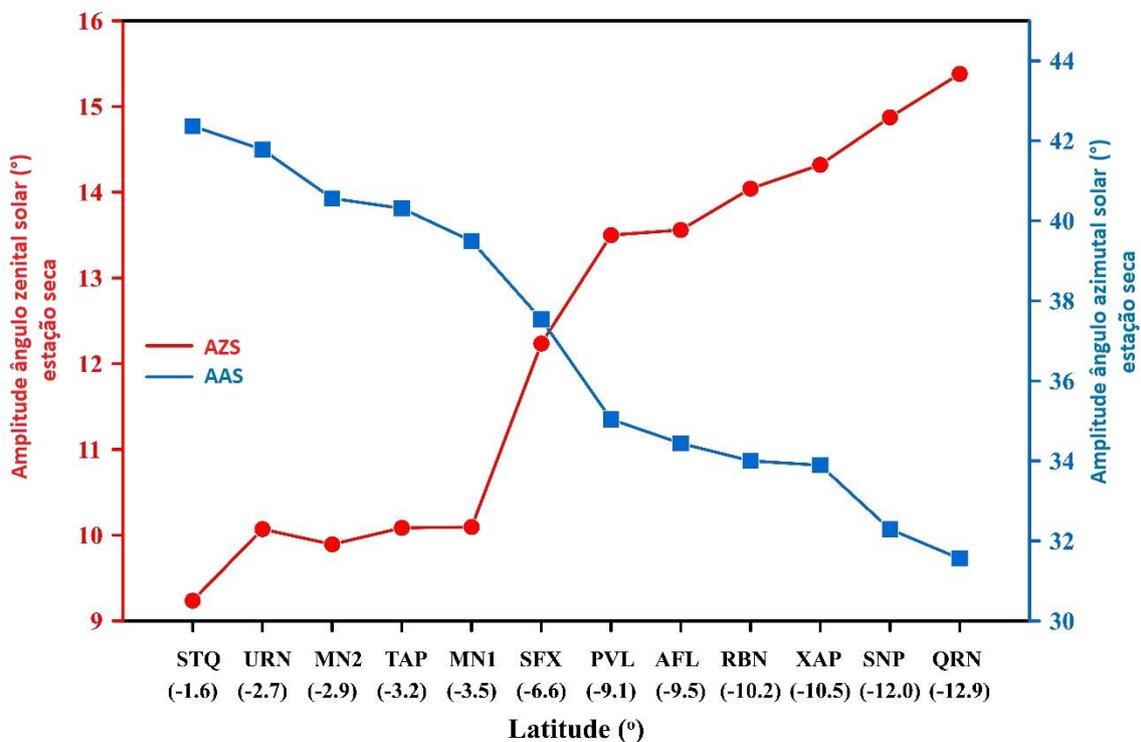
As primeiras seis áreas estão localizadas na região norte da Amazônia, enquanto as outras estão localizadas na parte sul da região (mais de 7° Sul de latitude). O AZS diminui de junho para setembro, enquanto o AAS aumenta no mesmo período.

Fonte: Elaborado pelo autor.

Enquanto a amplitude do AZS entre o início e o final da estação seca aumentou de norte para o sul da Amazônia, o AAS apresentou comportamento contrário, como pode ser observado na Figura 4.3. As maiores amplitudes de AZS (AZS de junho menos AZS de setembro) foram observadas em áreas localizadas ao sul da Amazônia. É o caso dos sítios RBN (14.0°), XAP (14.3°), SNP (14.9°) e

QRN (15.4°). Em contrapartida, as maiores amplitudes na estação seca para o AAS, em valores absolutos, foram observadas para as áreas localizadas na região norte da Amazônia. Exemplos são STQ (42.4°), URN (41.8°), MN2 (40.6°) e TAP (40.3°) (Figuras 4.2 e 4.3). Os dois ângulos solares representam proporções distintas de espalhamento da radiação incidente no topo da vegetação, sendo as variações de AZS mais proeminentes no sul e as de AAS no norte da Amazônia.

Figura 4.3 - Mudanças por localização da área de estudo na amplitude do ângulo zenital solar (AZS) e ângulo azimutal solar (AAS) durante a aquisição de imagens PlanetScope (PS) no começo e no final da estação seca.



As 12 áreas de estudo estão ordenadas no gráfico considerando o aumento de latitude do norte para o sul da Amazônia. A amplitude do AZS aumenta do norte para o sul, enquanto a amplitude do AAS aumenta na direção oposta. Os resultados estão representados em valores absolutos obtidos nos metadados das imagens.

Fonte: Elaborado pelo autor.

### **4.3 Mudanças em brilho, reflectância e IVs na estação seca**

Causadas por mudanças temporais nos ângulos solares, principalmente AZS, quantidades reduzidas de sombras e quantidades aumentadas de espalhamento do dossel tendem a ser capturadas pela constelação PS ao final da estação seca da Amazônia, em setembro. Esses efeitos podem, em determinada magnitude, afetar o brilho observado da vegetação, a reflectância e, conseqüentemente, os IVs.

Com base na ACP, detectaram-se diferentes níveis de mudanças na estação seca para o brilho da vegetação entre as áreas de estudo (Tabela 4.2). Para as áreas MN2 e QRN, os valores correspondentes da matriz de componentes principais, quando a ACP foi aplicada às observações de reflectância de superfície medidas entre junho e setembro de 2018, mostraram altas correlações nas quatro bandas para a primeira componente principal (CP1) (Tabela 4.2). Os valores da matriz de componentes para a CP1 variaram de 0.616 (NIR) a 0.976 (verde) na área MN2, e de 0.845 (NIR) a 0.956 (azul) na área QRN, respectivamente. Sendo assim, a CP1 foi um indicativo do brilho da vegetação (reflectância média das bandas PS), pois as bandas PS tiveram contribuições semelhantes para explicar a variância da primeira componente (76.5% da variância para MN2 e 87.2% para QRN, na Tabela 4.2). Na ACP, para ambas as áreas, o teste de esfericidade de Barlett teve sua hipótese nula, rejeitada, de que a correlação matriz seria uma matriz identidade, com o valor- $p < 0.001$ . Este resultado indica que é pouco provável obter uma matriz identidade da matriz de correlação de uma população com baixa correlação. A medida de Kaiser-Meyer-Olkin (KMO) foi de 0.724 para MN2 e de 0.740 para QRN, indicando uma amostragem adequada para a ACP.

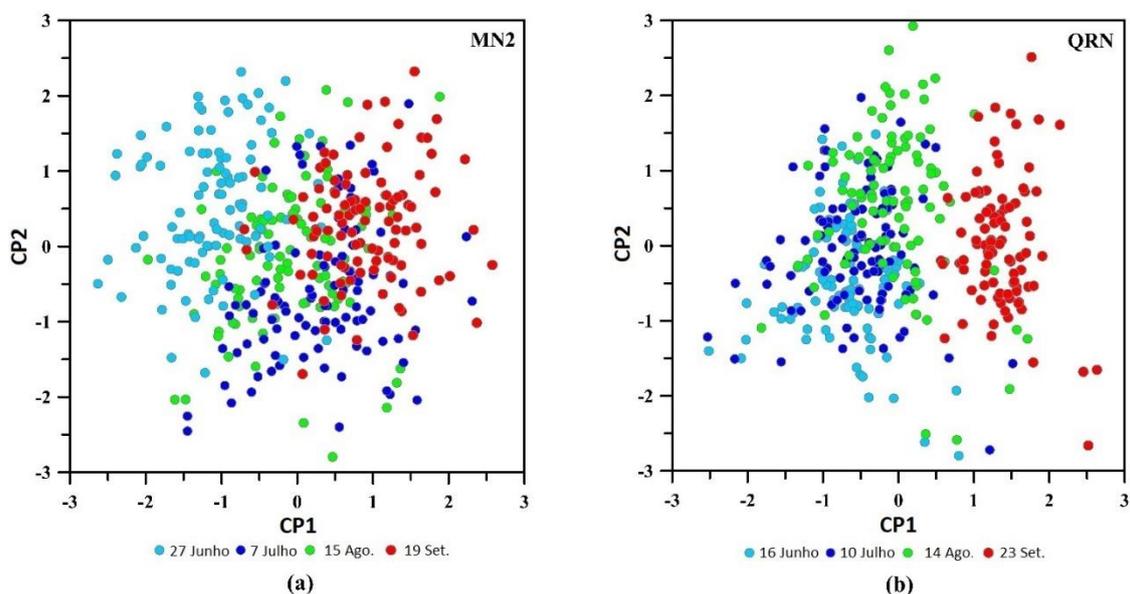
Tabela 4.2 – Autovetores resultantes da Análise por Componentes Principais (ACP) aplicada para observações PlanetScope, em valores de reflectância, na estação seca das áreas MN2 e QRN.

Bandas	MN2				QRN			
	CP1	CP2	CP3	CP4	CP1	CP2	CP3	CP4
Azul	0.915	-0.293	0.263	0.086	0.956	-0.144	-0.249	0.052
Verde	0.976	-0.052	-0.017	-0.209	0.888	-0.066	0.015	-0.141
Vermelho	0.943	-0.175	-0.264	0.105	0.940	-0.263	0.205	0.068
NIR	0.616	0.785	0.038	0.042	0.845	0.533	0.036	0.030
%Variância	76.5	18.4	3.5	1.6	87.2	9.4	2.6	0.7
%Cumulativa	76.5	94.9	98.4	100.0	87.2	96.6	99.2	100.0

Fonte: Elaborado pelo autor.

Quando se utilizou a matriz de coeficientes para gerar e projetar os valores das duas primeiras componentes principais para cada um dos 100 pixels extraídos por mês, entre junho e setembro, observou-se um agrupamento de dados no espaço CP (Figura 4.4). O brilho da vegetação aumentou do lado esquerdo para o direito do eixo CP1, que detectou maior espalhamento da energia incidente no dossel em setembro do que em junho, especialmente para dados PS medidos na área ao sul da Amazônia (QRN, Figura 4.4).

Figura 4.4 - Primeiros dois valores da Análise por Componentes Principais (ACP) aplicada a dados de reflectância de superfície das quatro bandas PlanetScope.

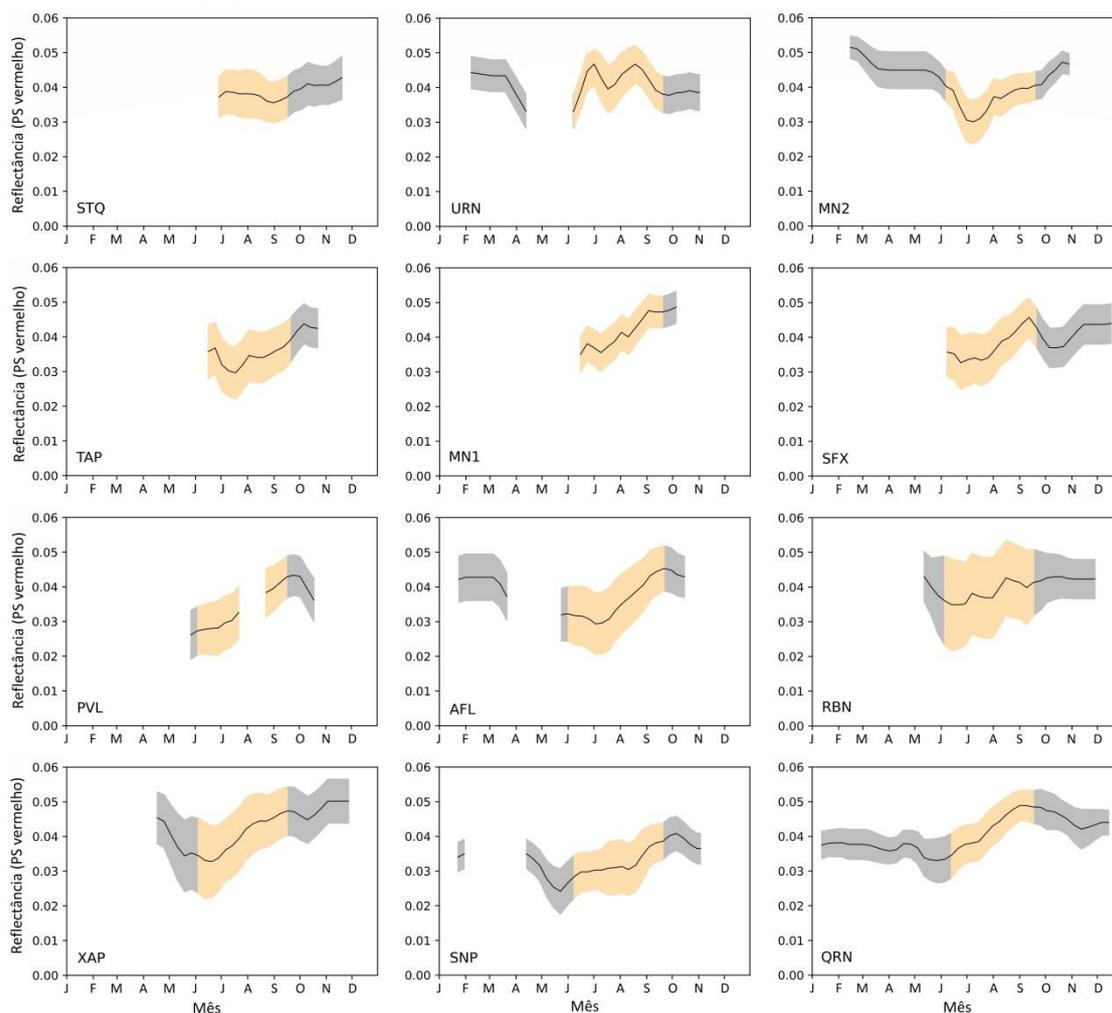


Os valores mostram variações no brilho da vegetação do início (Junho) para o final (Setembro) de 2018.

Fonte: Elaborado pelo autor.

Também foram analisados os perfis sazonais de reflectância para cada área, usando os dados PS obtidos entre 2017 e 2019. Ao se inspecionar a reflectância de superfície média das bandas PS do vermelho e do NIR, confirmaram-se as mudanças sazonais observadas pela ACP. Do início para o final da estação seca, um incremento geral, tanto na reflectância do vermelho (Figura 4.5), quanto na do NIR (Figura 5.6), foi observado para cada uma das 12 áreas de estudo selecionadas. Um comportamento similar no espalhamento da radiação solar pelo dossel também foi registrado nas bandas do azul e verde (resultados não mostrados). Nas Figuras 4.5 e 4.6, a variabilidade dos dados foi maior para o vermelho do que para o NIR, provavelmente por causa da maior influência de espalhamento atmosférico residual, geralmente presente em maior quantidade na reflectância das bandas do visível.

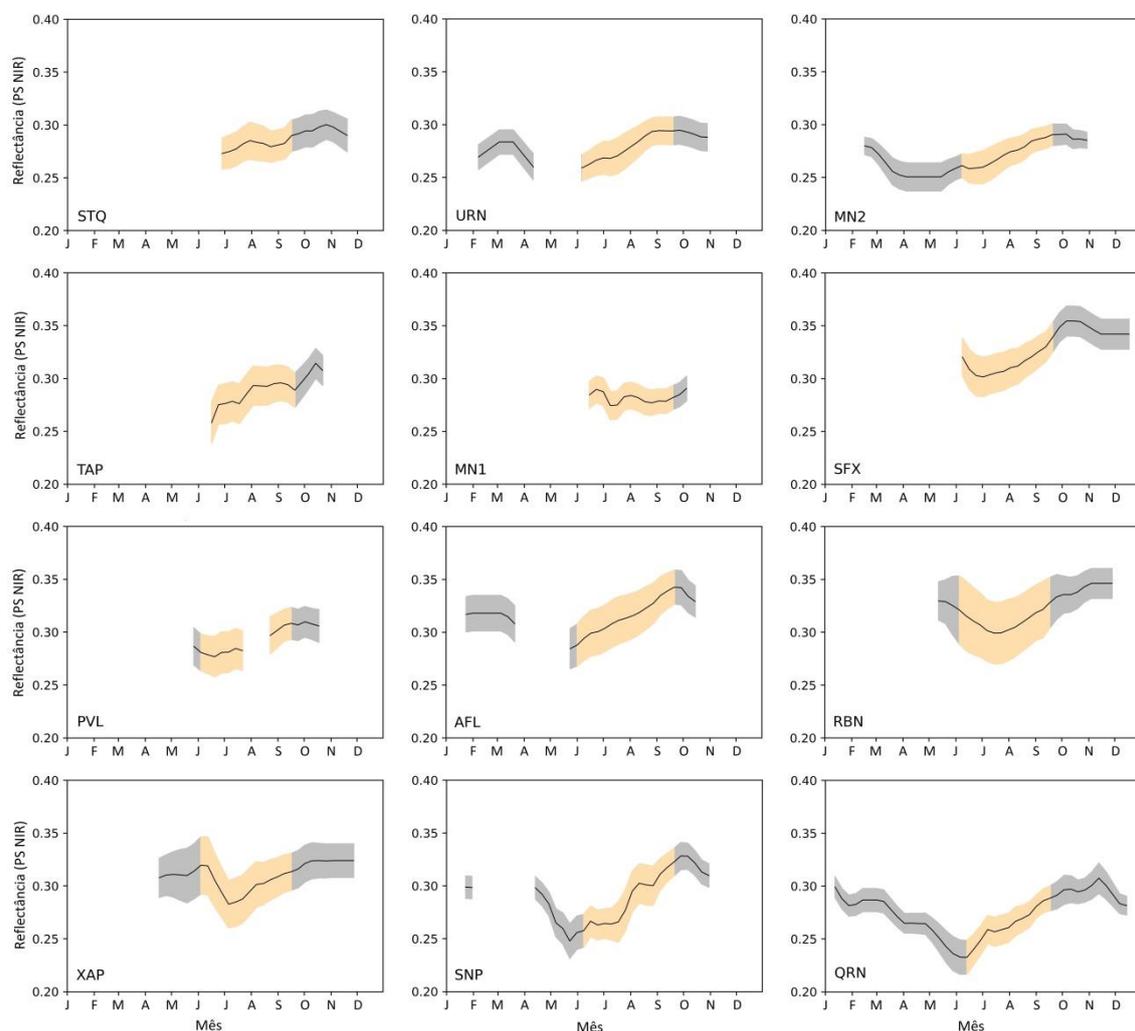
Figura 4.5 - Variações sazonais na reflectância de superfície média da banda 3 dos dados PS (vermelho) calculada para cada área de estudo entre 2017 e 2019.



As áreas estão organizadas em latitude crescente do Norte para o Sul da Amazônia. A reflectância média do vermelho tende a aumentar em direção ao final da estação seca em setembro (dados em amarelo). Intervalos de 95% de confiança são apresentados. Espaços vazios nas curvas indicam dados faltantes em ao menos dois dos três anos analisados.

Fonte: Elaborado pelo autor.

Figura 4.6 - Variações sazonais na reflectância média do NIR (banda 4) de dados PS calculadas para cada área de estudo entre 2017 e 2019.



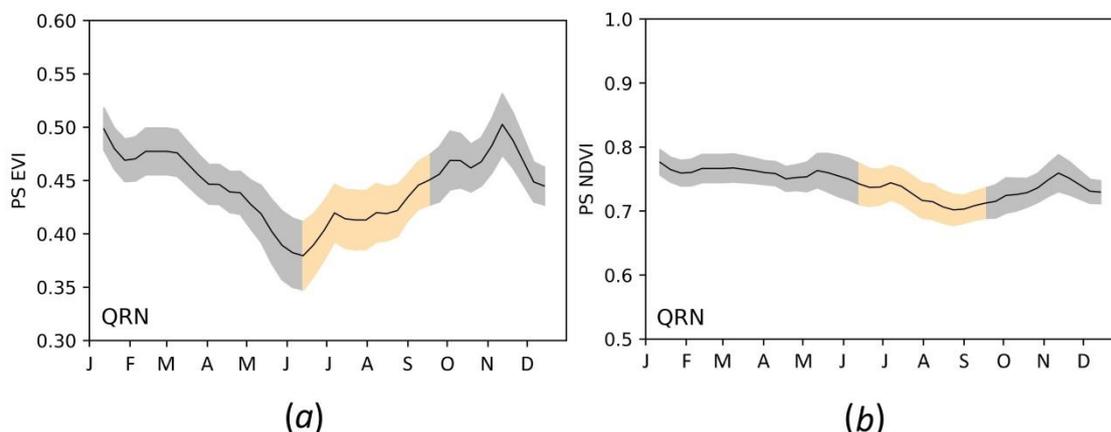
As áreas de estudo estão organizadas por latitude crescente do norte para o sul da Amazônia. A reflectância média do NIR tende a aumentar em direção ao final da estação seca em setembro (cor amarela). Intervalos de confiança de 95% estão indicados. Espaços vazios nas curvas indicam dados faltantes em ao menos dois dos três anos analisados.

Fonte: Elaborado pelo autor.

O aumento da reflectância de junho até setembro, ilustrado nas Figuras 4.5 e 4.6, afetou diretamente a determinação do NDVI e do EVI. Por conta da grande influência da reflectância do NIR no cálculo do índice EVI, este índice seguiu a trajetória geral observada para o NIR durante a estação seca (Figura 4.7). Por sua vez, por causa da diferença normalizada entre pares de bandas utilizadas pelo NDVI, o aumento na reflectância de ambas as bandas do vermelho (Figura

4.5) e do NIR (4.6), reduziu os efeitos de iluminação solar no cálculo do índice (Figura 4.7).

Figura 4.7 - Variação sazonal do (a) EVI e (b) NDVI médios, calculados a partir de dados PlanetScope na área de estudo QRN.

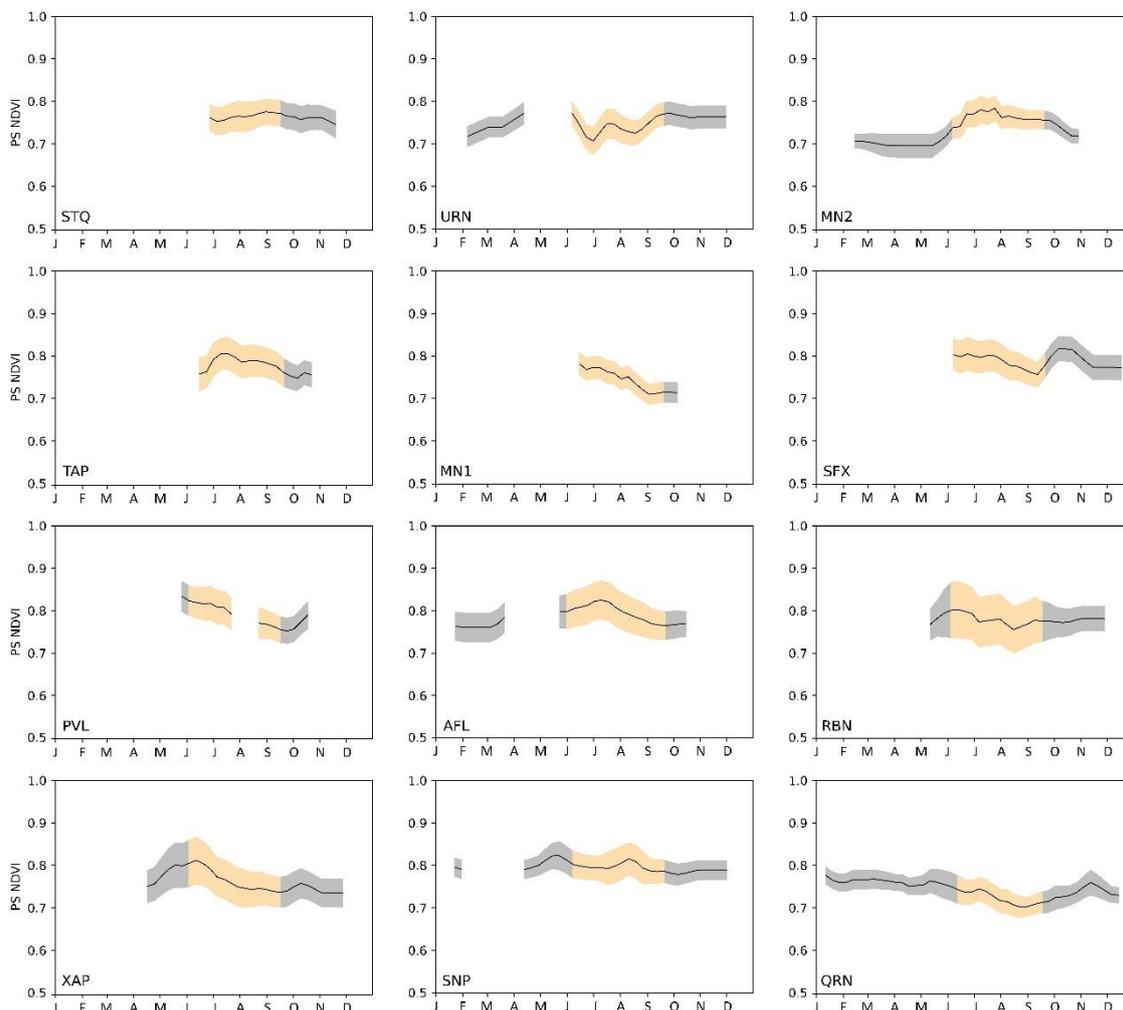


As curvas de desvio-padrão estão apresentadas. O EVI aumenta do início para o final da estação seca (em amarelo), enquanto o NDVI não apresenta mudanças substanciais no mesmo período.

Fonte: Elaborado pelo autor.

Na Figura 4.8, pode-se observar os resultados para todas as áreas de estudo utilizando dados PS para o cálculo do NDVI. Conforme visto anteriormente, os resultados indicam uma menor sazonalidade do índice. Também é possível observar, de forma geral, uma ligeira diminuição do NDVI do início para o final da estação seca com o uso de dados PS. Este é um resultado importante para a discussão da fenologia de dosséis de florestas tropicais na Amazônia, significando que, por mais sensível que se apresente, evidencia um sinal oposto ao tradicionalmente reportado na literatura para o EVI como um possível sinal com componente biofísica. Como um índice também relacionado ao vigor vegetativo, o NDVI não seguiu o mesmo padrão.

Figura 4.8 - Variação sazonal do NDVI médio, calculado a partir de dados PlanetScope para todas as áreas de estudo.



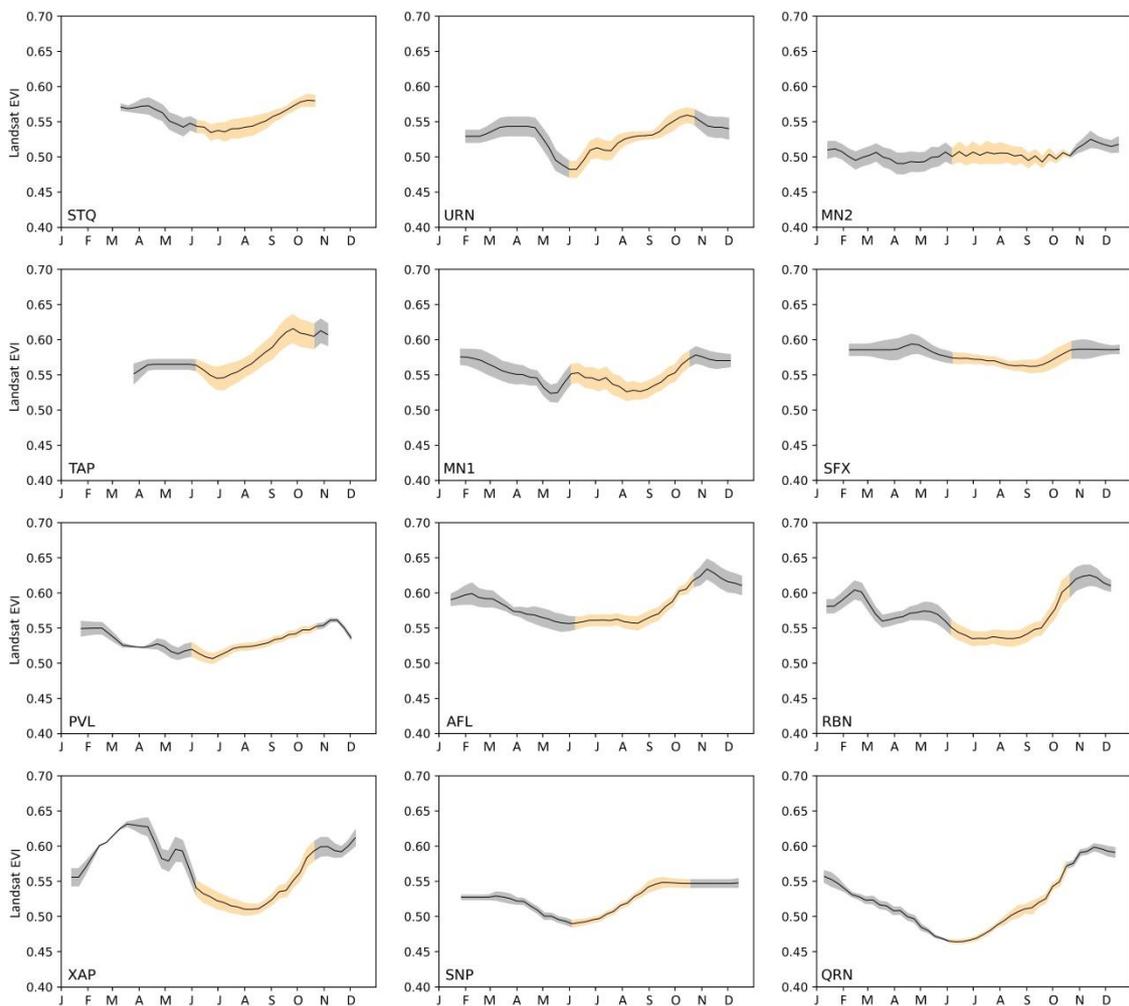
A estação seca é representada em amarelo. As curvas de desvio-padrão também estão apresentadas.

Fonte: Elaborado pelo autor.

Os IVs, calculados dos dados PS, foram replicados para os dados Landsat-8, utilizando os mesmos métodos para preencher as séries temporais interanuais nas diferentes áreas de estudo. Na Figura 4.9, pode-se observar os padrões de aumento do EVI durante a estação seca na maioria das áreas de estudo, à exceção de MN2. Em um contexto geral, esse comportamento de MN2 pode ser atribuído à ausência de observações, mesmo na combinação de três anos consecutivos. O mesmo fator, em comparação com os dados PS, gerou curvas de desvio padrão menores. O menor desvio padrão geral observado em dados

Landsat também pode ser explicado, parcialmente, pela menor variabilidade ocasionada pela resolução espacial média de 30 metros, que agrega parcialmente os efeitos de sombra. No caso das curvas Landsat, não se descartou perfis com menos de duas observações em datas próximas. Essa foi uma característica necessária para compor séries temporais contínuas neste tipo de dado, cujo tempo de revisita de cena é de 16 dias.

Figura 4.9 - Variação sazonal do EVI médio, calculado a partir de dados OLI/Landsat-8 para todas as áreas de estudo.

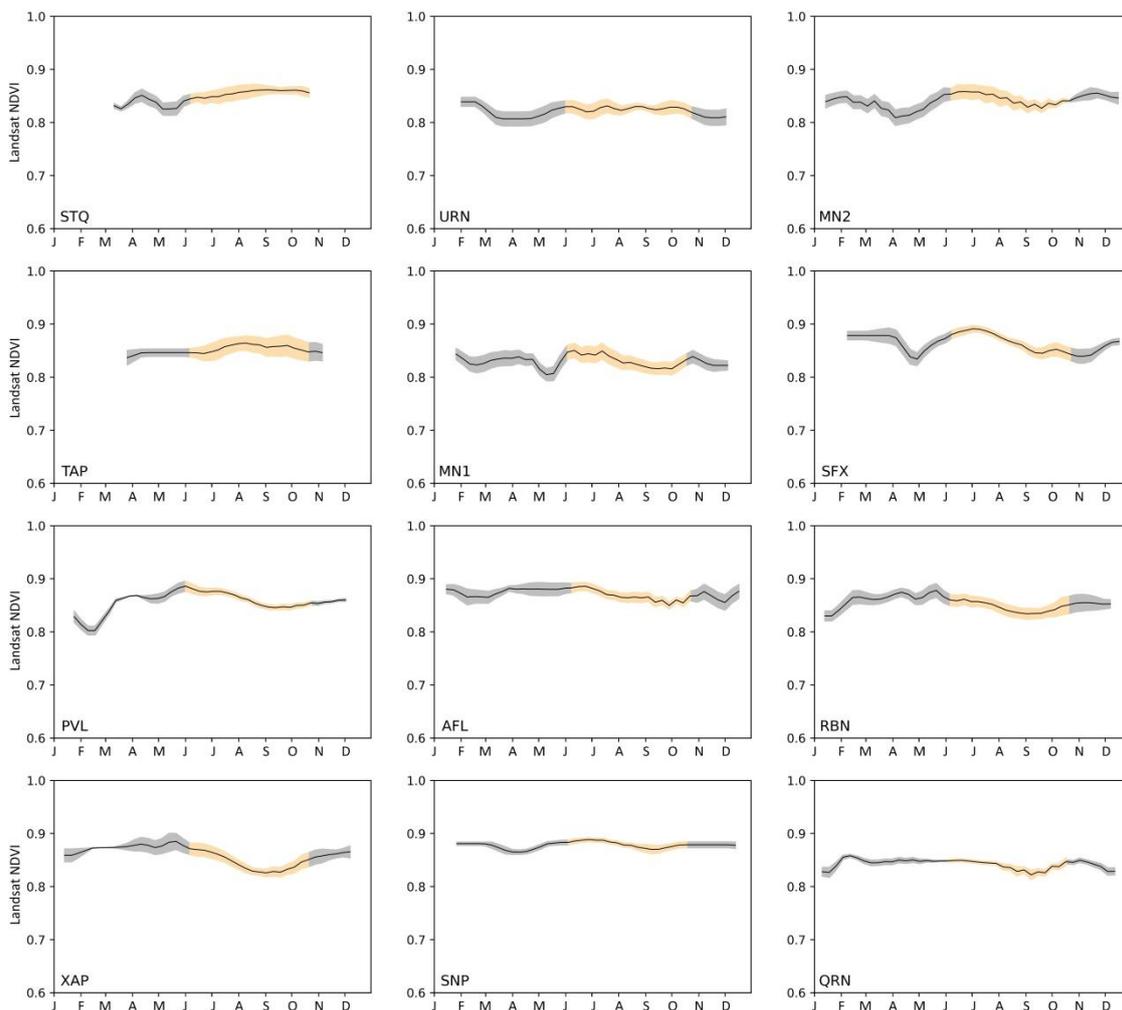


A estação seca é representada em amarelo. As curvas de desvio-padrão também estão apresentadas.

Fonte: Elaborado pelo autor.

De forma similar aos resultados observados com dados PS, as curvas sazonais do NDVI para os dados Landsat-8 (média de 2017 a 2019), ilustradas na Figura 4.9, apresentaram comportamento pouco variável ao longo da estação seca, sem um padrão definido de aumento ou diminuição do índice. Mesmo ao longo de todo o ano, é possível observar a estabilidade da resposta do dossel das florestas tropicais, com aumento de variabilidade apenas para áreas de transição como os sítios XAP, SNP e QRN (Figura 4.10). Pequenas reduções nos valores de NDVI do Landsat ao final da estação seca foram observadas em alguns sites como MN1, MN2, SFX, PVL, AFL, RBN e XAP; todas dentro dos intervalos de confiança. Pequenos incrementos de NDVI em setembro foram registrados apenas em STQ (Figura 4.9).

Figura 4.10 - Variação sazonal do NDVI médio, calculado a partir de dados OLI/Landsat-8 para todas as áreas de estudo.



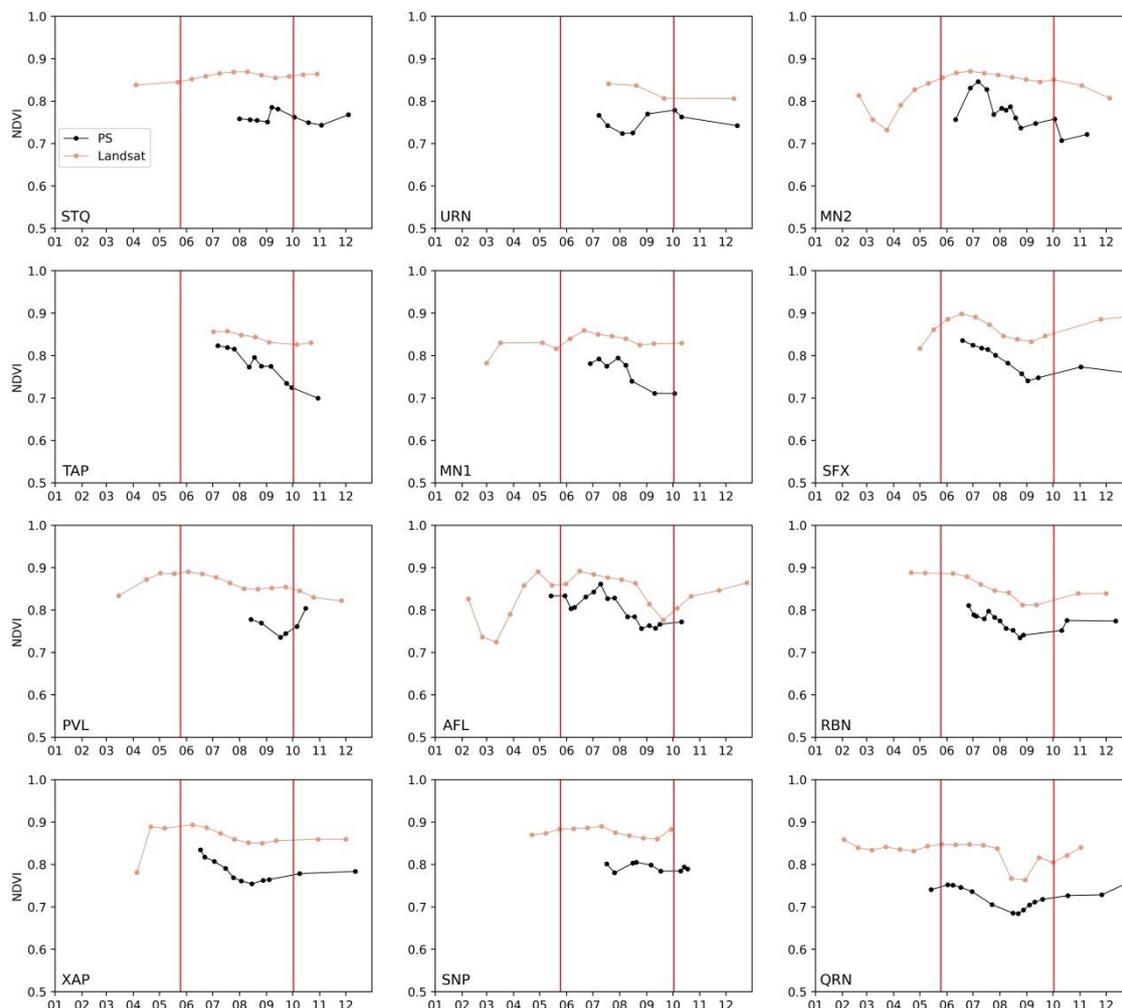
Desvios padrão também estão apresentados. Nos gráficos, a estação seca está representada pela cor amarela.

Fonte: Elaborado pelo autor.

Por fim, a Figura 4.11 ilustra o comportamento do NDVI por área de estudo, para o ano de 2017, derivado dos dados PS e Landsat-8. O ano de 2017 foi selecionado por apresentar uma maior frequência de observações, quando combinados todos os sensores. Selecionou-se o índice menos anisotrópico (NDVI), como base para a comparação direta. Pode-se observar que as curvas dos dados PS seguem valores, em média, inferiores aos obtidos para o Landsat. Este resultado era esperado, considerando a configuração diferente das bandas do vermelho e NIR destes sensores e suas diferentes resoluções

espaciais. Portanto, este resultado pode estar relacionado à alta resolução espacial do PS, especialmente suas bandas mais largas e sua capacidade intrínseca de concentrar respostas específicas de pixels sombreados no dossel, associando também valores mais baixos para a média das amostragens de 1.000 pixels. O horário de passagem no Equador da constelação de satélites também difere dos horários do Landsat, o que representa diferentes possibilidades de dosséis iluminados e sombreados vistos pelos CubeSats.

Figura 4.11 - Curvas do NDVI para o ano de 2017 utilizando dados PS (3.7 m de resolução espacial) e Landsat (30 m).

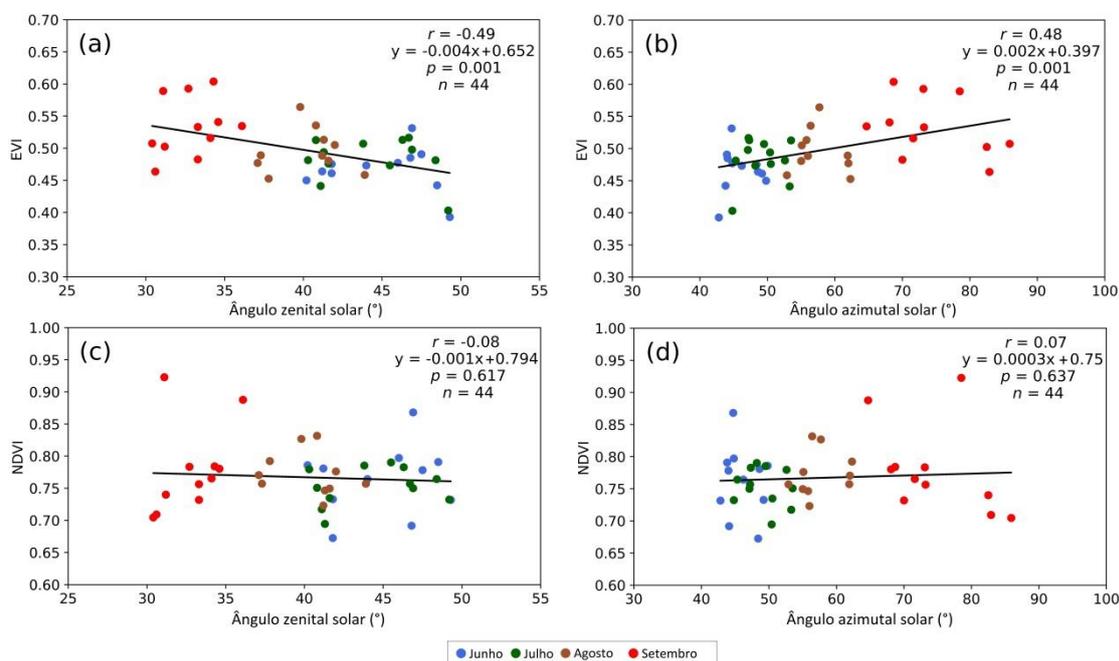


Os dados PS e Landsat tiveram amostragens aleatórias de 1.000 pixels por área de estudo. As linhas vermelhas verticais indicam o início e final da estação seca.

Fonte: Elaborado pelo autor.

Retomando a análise dos dados PS, como um índice mais anisotrópico aos efeitos da iluminação solar do que o NDVI, o EVI se apresentou inversamente correlacionado com o AZS ( $r = -0.49$ ) e positivamente correlacionado com o AAS ( $r = 0.48$ ) (Figuras 4.12a e 4.12b). Os coeficientes de correlação de Pearson para o NDVI foram de  $-0.08$  (AZS) e  $0.07$  (AAS) (Figuras 4.12c e 4.12d). Estes resultados refletem o conjunto total dos sítios estudados e tendem a ser mais fortes se cada sítio for considerado separadamente pela influência diferenciada dos ângulos solares de norte para o sul da Amazônia.

Figura 4.12 - Relações entre o EVI e (a) ângulo zenital solar (AZS) e (b) ângulo azimutal solar (AAS) utilizando as 12 áreas de estudo selecionadas.



Resultados correspondentes para o NDVI estão apresentados em (c) e (d), respectivamente. Foram utilizadas observações PlanetScope no meio de cada mês de junho a setembro de 2018 (média de 1.000 pixels amostrados por área e por data).

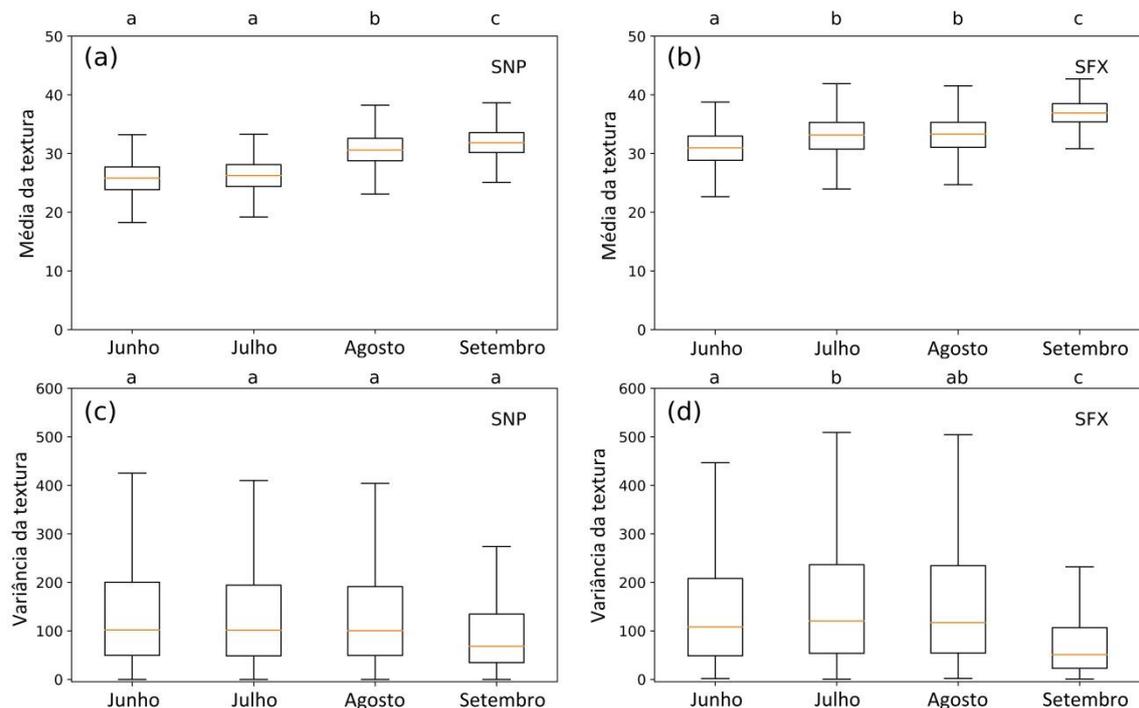
Fonte: Elaborado pelo autor.

#### 4.4 Variações em métricas de textura (GLCM) na estação seca

Considerando que variações nas condições de iluminação da vegetação e do terreno vistas pelos CubeSats podem alterar a textura da imagem, analisou-se as métricas GLCM de textura. Esta análise capturou variações texturais utilizando os dados de alta resolução espacial da banda NIR (banda 4) da PS. Entretanto, para as 8 métricas calculadas, apenas a média da textura e a variância da textura mostraram padrões bem definidos para as diferentes áreas de estudo. Por exemplo, a média da textura aumentou do início para o final da estação seca nas áreas SNP (Figura 4.13a) e SFX (Figura 4.13b). As duas áreas apresentaram diferenças estatisticamente significativas na média da textura em nível de confiança de 1% (teste Tukey-Kramer). Os testes são indicados pelas letras no topo da Figura 4.12. Com tendência oposta à média da textura, a métrica variância da textura diminuiu de junho para setembro para

a maior parte das áreas de estudo. Entretanto, nas Figuras 4.13c e 4.13d, as diferenças observadas se apresentaram estatisticamente significativas apenas para a área SFX.

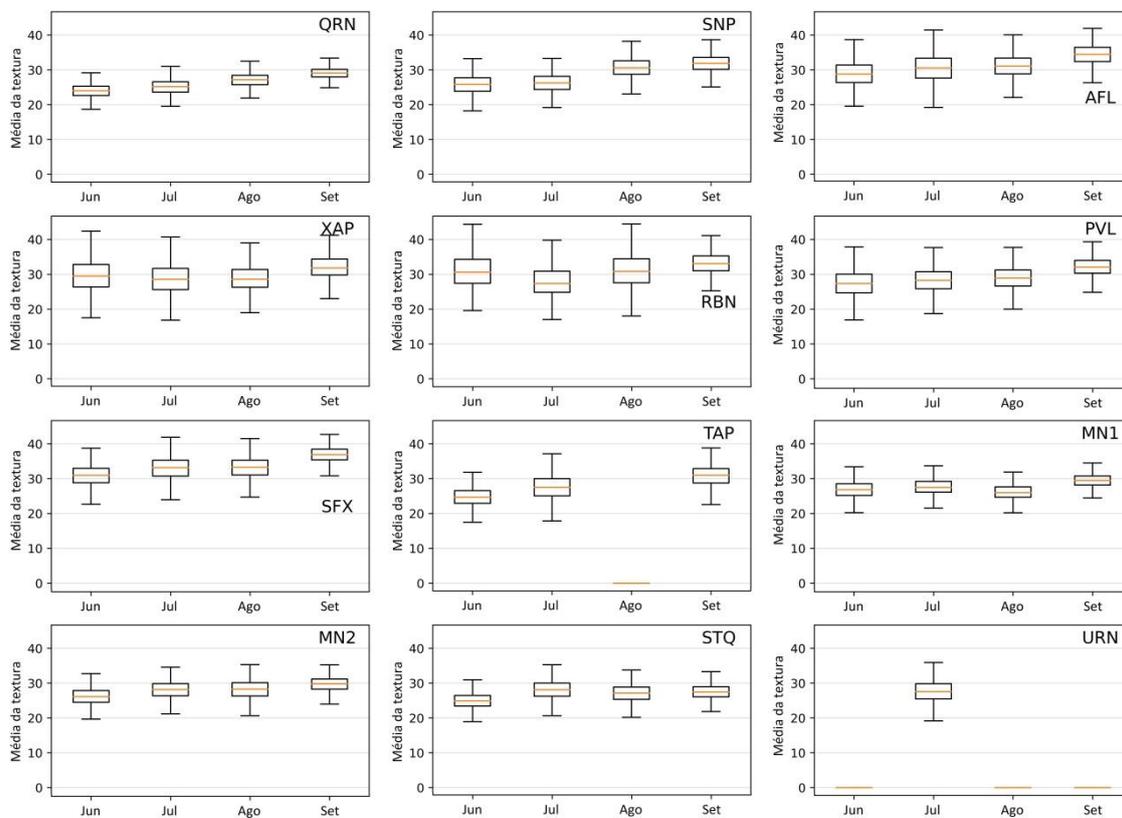
Figura 4.13 - Variações na média de textura GLCM durante a estação seca para as áreas (a) SNP e (b) SFX. Resultados para a variância da textura GLCM das mesmas áreas estão ilustradas em (c) e (d).



Ambas as métricas foram calculadas partir do NIR (banda 4) dos dados PlanetScope utilizando 1.000 pixels por área entre 2017 e 2019. As letras no topo das Figuras indicam a significância estatística da diferença entre datas em um intervalo de confiança de 1% (teste Tukey-Kramer).  
 Fonte: Elaborado pelo autor.

Os resultados completos para os dados de média e variância da textura PS são apresentados nas Figuras 4.14 e 4.15. De forma geral, os padrões de diminuição na variância e aumento da média se repetiram para as outras áreas de estudo não apresentadas na Figura 4.13. Entretanto, os resultados de significância estatística não foram calculados para todos os casos. É importante mencionar que as áreas TAP e URN apresentaram dados ausentes e/ou inconsistentes em um dado mês, impossibilitando a comparabilidade com outros meses e a construção dos boxplots para os respectivos meses.

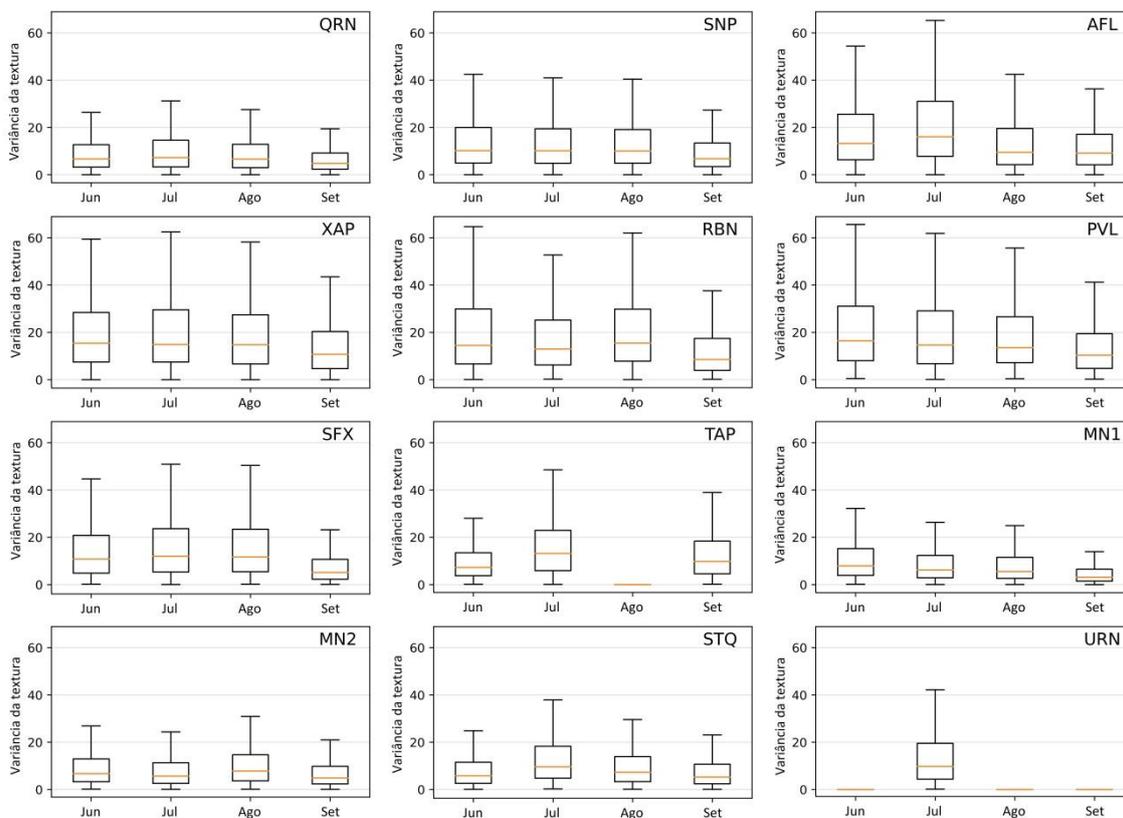
Figura 4.14 - Variações na média de textura GLCM durante a estação seca para as doze áreas de estudo.



A métrica foi calculada partir do NIR (banda 4) dos dados PlanetScope utilizando 1.000 pixels por área.

Fonte: Elaborado pelo autor.

Figura 4.15 - Variações na variância de textura GLCM durante a estação seca para as doze áreas de estudo.

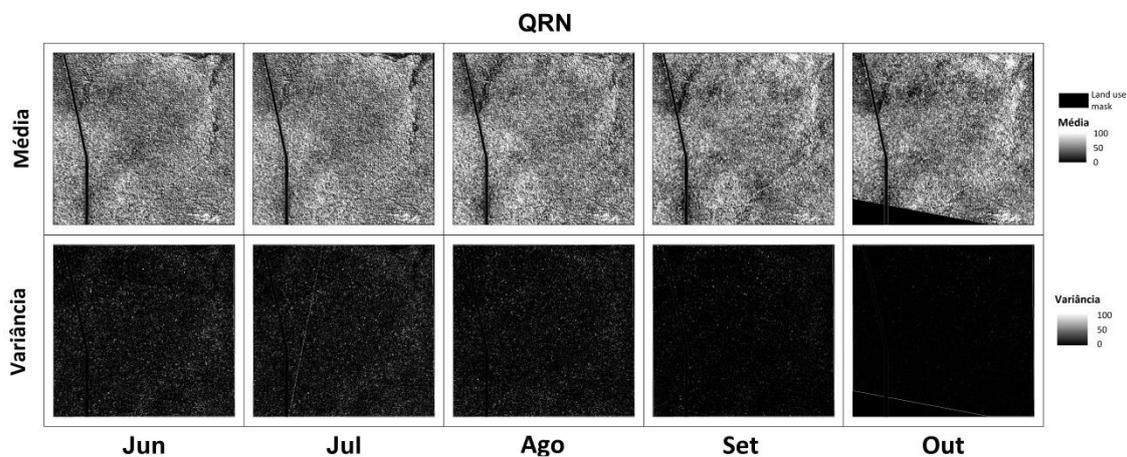


A métrica foi calculada partir do NIR (banda 4) dos dados PlanetScope utilizando 1.000 pixels por área.

Fonte: Elaborado pelo autor.

A espacialização dos resultados para as métricas de textura teve resultados semelhantes aos boxplots acima, conforme pode-se observar nas Figuras 4.16, 4.17 e 4.18 para as áreas QRN, PVL e SNP, respectivamente. No entanto, os efeitos de aumento da média da textura foram menos perceptíveis do que aqueles associados à diminuição da variância, quando observados em níveis de cinza. Isso se deve ao comportamento distinto das duas métricas quando presentes em imagens: enquanto a média será representada por um aumento de brilho, mais sensível em uma visualização espacializada, a variância terá sua mudança do início para o final da estação seca representada por uma uniformização da imagem.

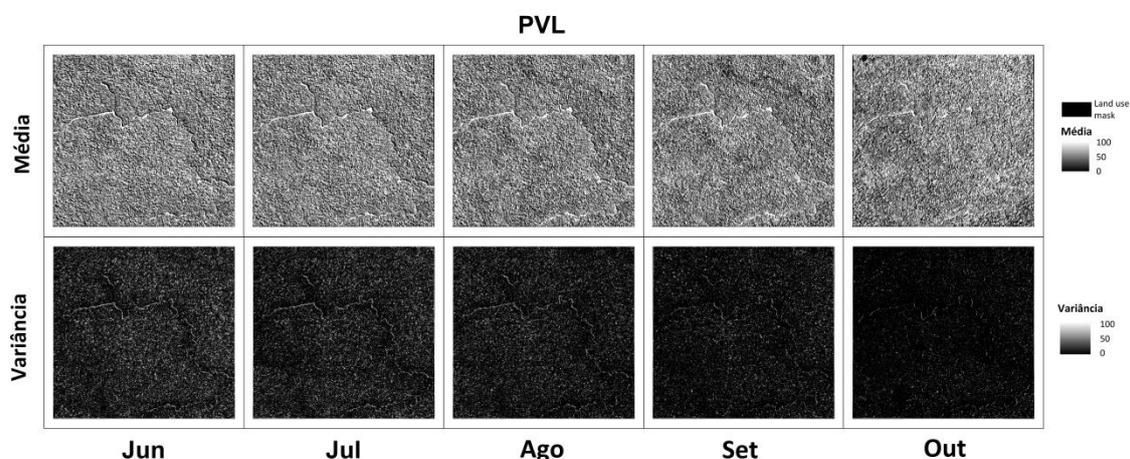
Figura 4.16 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo QRN utilizando dados PlanetScope.



A média mostra alterações sensíveis no brilho com o tempo, enquanto a variância produz uma uniformização da cena observada em direção a setembro.

Fonte: Elaborado pelo autor.

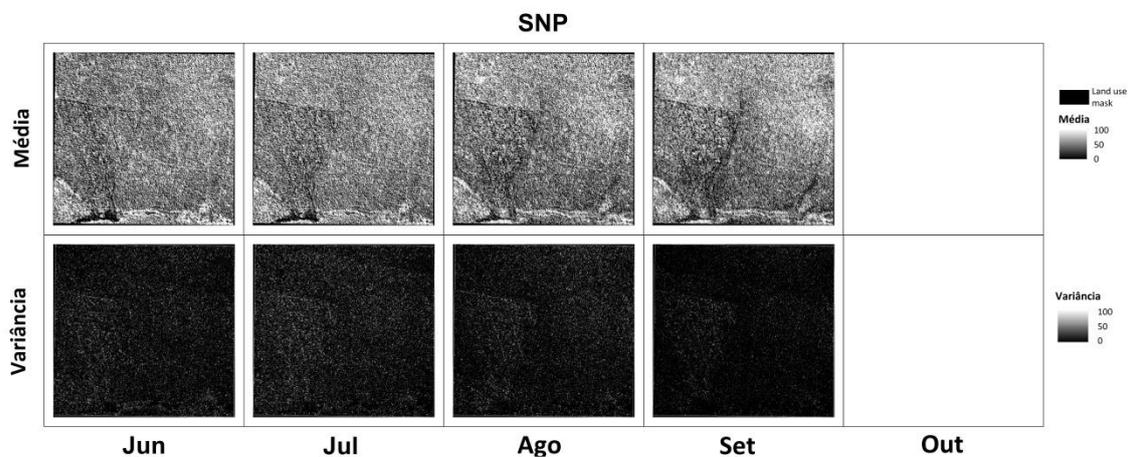
Figura 4.17 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo PVL utilizando dados PlanetScope.



A média mostra alterações sensíveis no brilho com o tempo, enquanto a variância produz uma uniformização da cena observada em direção a setembro.

Fonte: Elaborado pelo autor

Figura 4.18 - Variações espaciais nas métricas de textura média e variância GLCM para a área de estudo SNP utilizando dados PlanetScope.

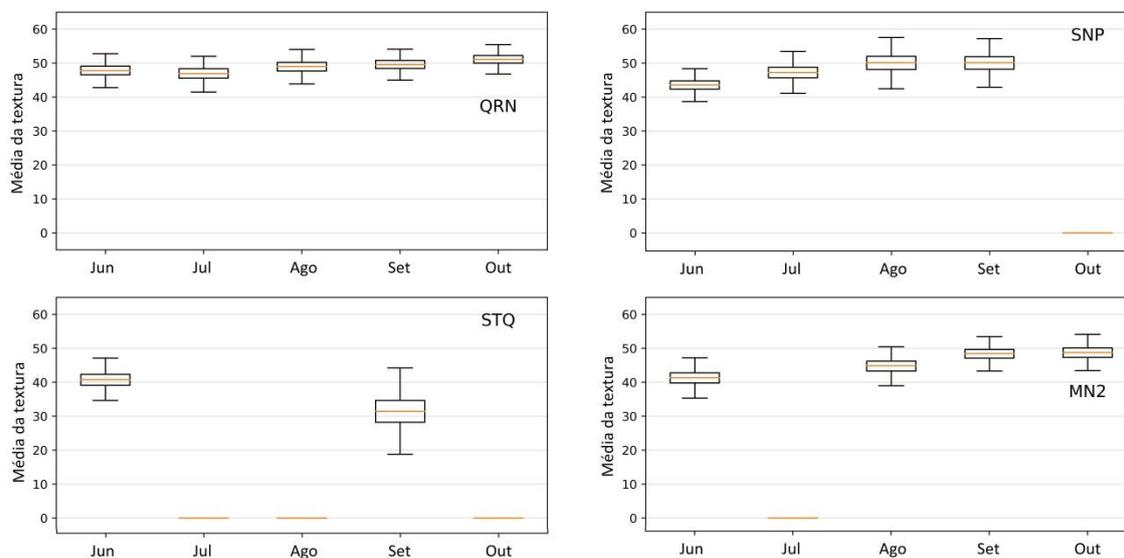


A média mostra alterações sensíveis no brilho com o tempo, enquanto a variância produz uma uniformização da cena observada em direção a setembro.

Fonte: Elaborado pelo autor.

Por sua vez, os resultados obtidos para a média da textura utilizando dados OLI/Landsat-8 mostraram o mesmo padrão de incremento deste atributo em direção a setembro para as áreas de estudo QRN, SNP e MN2 (Figura 4.19). A área STQ, entretanto, apresentou uma queda entre os meses de junho e setembro. Apesar disso, apenas os dois meses comparados tiveram observações válidas em datas próximas ao meio de cada mês. Este resultado, portanto, é apenas um indicativo parcial de não concordância da área com os resultados obtidos com imagens PS. Métricas estatísticas entre datas não foram aplicadas devido à presença de meses sem cobertura de imagens válidas no critério metodológico adotado.

Figura 4.19 - Variações na média de textura GLCM do OLI/Landsat-8 durante a estação seca para as doze áreas de estudo.

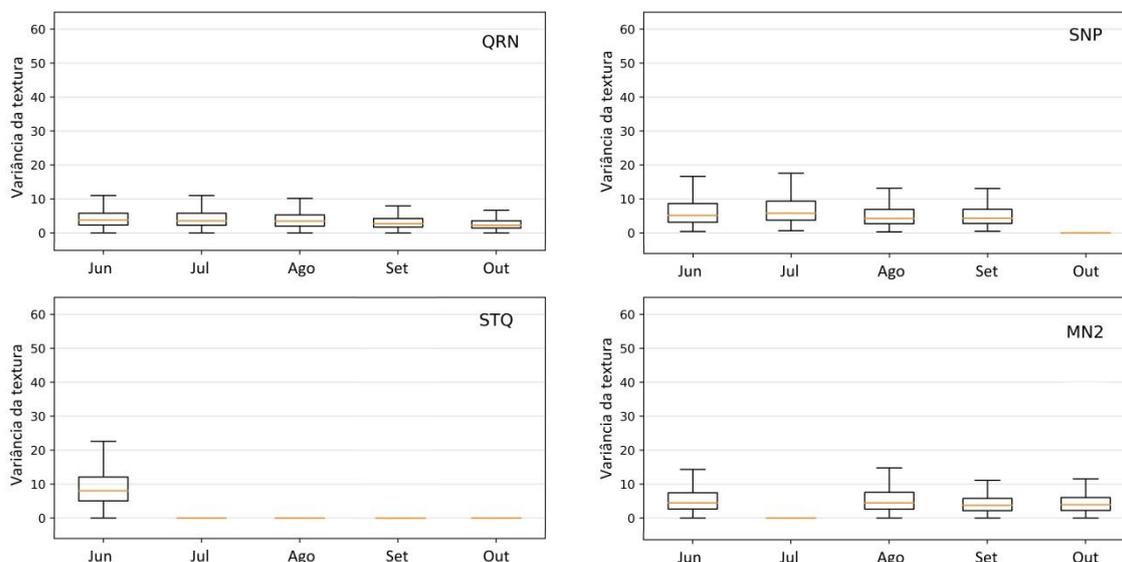


A métrica foi calculada partir do NIR (banda 5) dos dados OLI/Landsat-8 utilizando 1.000 pixels por área.

Fonte: Elaborado pelo autor.

A variância da textura calculada para os dados OLI/Landsat-8 apresentou a mesma tendência de diminuição do início para o final da estação seca para as áreas QRN, SNP e MN2 (Figura 4.20). Assim como na análise da média da textura, a variância para o mês de setembro na área STQ indicou uma tendência contrária, com variância não condizente com a observação de junho. Sem o fator comparativo dos outros meses, onde não se obteve observações válidas para essa área, é impossível afirmar a existência de um outro padrão. De todo modo, o padrão não se repete em dados PS para a mesma área e período. Novamente, métricas estatísticas entre datas não foram aplicadas devido à presença de meses sem cobertura de imagens válidas no critério metodológico adotado.

Figura 4.20 - Variações na variância de textura GLCM dos dados OLI/Landsat-8 durante a estação seca para as doze áreas de estudo.

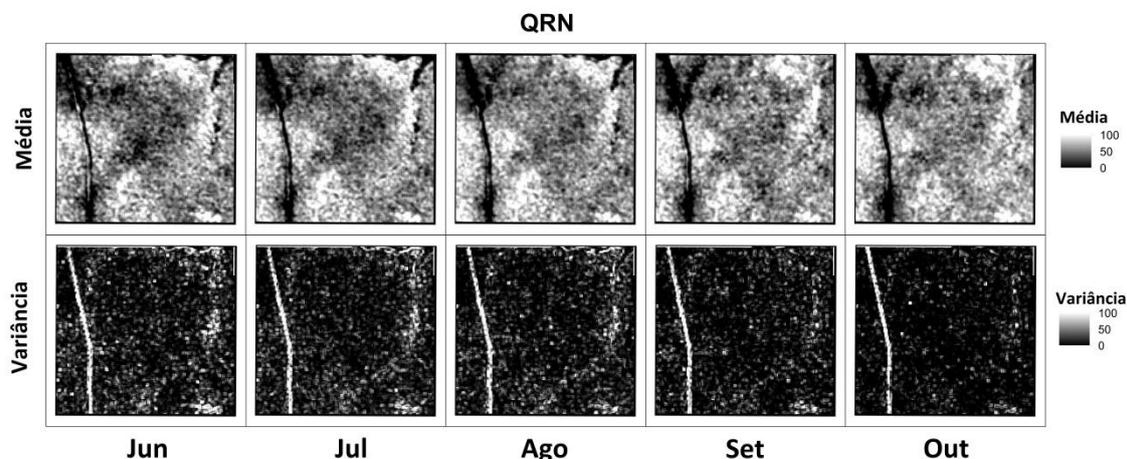


A métrica foi calculada partir do NIR (banda 5) dos dados OLI/Landsat-8 utilizando 1.000 pixels por área.

Fonte: Elaborado pelo autor.

Assim como na análise espacializada dos dados PS, os dados Landsat-8 apresentaram sensível aumento no brilho aparente na cena, enquanto a variância foi representada por uma uniformização da cena observada, de forma geral. A Figura 4.21 apresenta os resultados obtidos para QRN. É notável, também, as diferenças na nitidez das observações em relação aos dados PS, quando comparados à resolução de 30 metros do Landsat-8.

Figura 4.21 - Variações espacializadas nas métricas de textura média e variância do OLI/Landsat-8 para a área de estudo QRN.

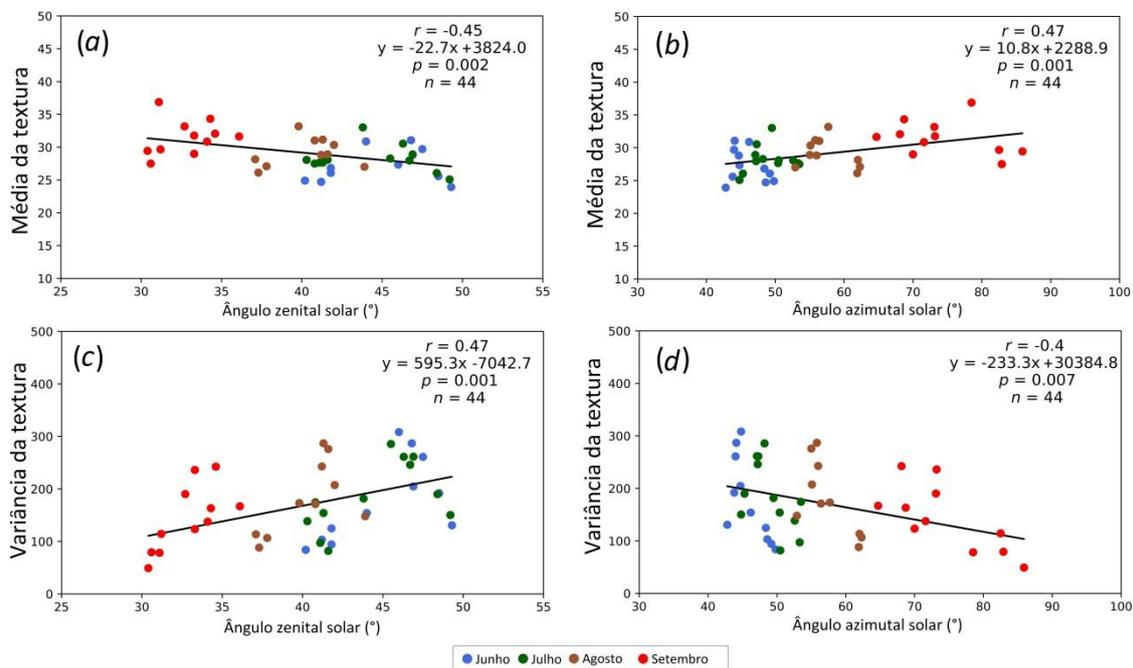


A média sofre alterações sensíveis no brilho com o tempo, enquanto a variância produz uma uniformização da cena observada em direção a setembro.

Fonte: Elaborado pelo autor.

Os resultados da Figura 4.22 indicam que os efeitos de iluminação solar produziram alterações na textura das imagens capturadas pela constelação PS durante a estação seca na Amazônia. A média e a variância da textura dos dados PS foram correlacionados com o AZS e o AAS (Figura 4.22). A média da textura reduziu ( $r = -0.45$  na Figura 4.22a) e a variância aumentou ( $r = +0.47$  na Figura 4.21b) seguindo o aumento do AZS. Correlações positivas ( $r = +0.47$ ) e negativas ( $r = -0.40$ ) foram obtidas para ambas as métricas com o AAS (Figuras 4.22c e 4.22d). As mudanças texturais foram, portanto, causadas pelo maior espalhamento da energia incidente pelo dossel e pela reduzida quantidade de sombras projetadas pelo dossel observadas pela constelação de satélites sob redução do AZS e aumento do AAS em direção ao final da estação seca (setembro).

Figura 4.22 - Relações entre as médias da textura GLCM PS com o ângulo zenital solar (AZS) e o ângulo azimutal solar (AAS) em (a) e (b), respectivamente. Os resultados correspondentes para a variância da textura estão em (c) e (d).

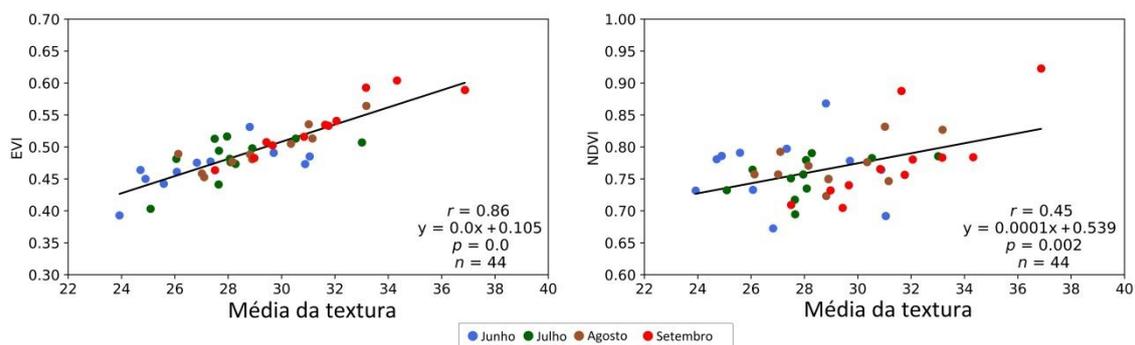


Observações PlanetScope em meados de cada mês (junho a setembro) para as áreas de estudo selecionadas (1.000 pixels por área e por data) foram utilizadas nos cálculos.

Fonte: Elaborado pelo autor.

A média foi mais fortemente correlacionada com o EVI ( $r = +0.86$  na Figura 4.23a) do que com o NDVI ( $r = +0.45$  na Figura 4.23b). Esse resultado expressa a maior anisotropia do EVI aos efeitos de iluminação solar, a forte dependência deste índice em relação à resposta da banda NIR e também as mudanças em componentes de iluminação e sombra no dossel observadas pelos sensores.

Figura 4.23 - Relações da média da textura GLCM PS com (a) EVI e (b) NDVI.



(a)

(b)

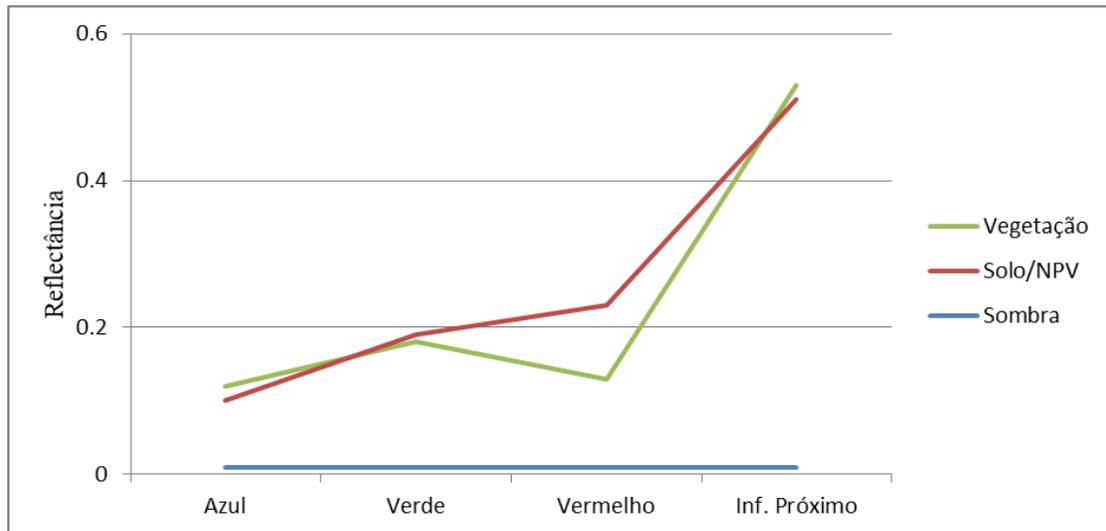
Observações PlanetScope no meio de cada mês (Junho a Setembro) para as áreas de estudo selecionadas (1.000 pixels por área e por data) foram utilizadas para os cálculos.

Fonte: Elaborado pelo autor.

#### 4.5 Variações em frações-sombra e sensibilidade de IVs às condições de iluminação da vegetação e terreno durante a estação seca

O modelo linear de mistura espectral com três *endmembers* (vegetação verde, solo e sombra) também capturou variações na quantidade de sombras no dossel observadas pelos dados PS ao longo da estação seca. Como exemplo dos *endmembers* obtidos, a Figura 4.24 apresenta os *endmembers* para a área de estudo QRN no mês de junho. Composições coloridas das imagens-frações para o mês de junho são apresentadas na Figura 4.23 para os diferentes sites, mostrando a heterogeneidade nas condições de iluminação da vegetação e do terreno entre as áreas estudadas. É preciso destacar, ainda, que a área STQ apresentou resultados insatisfatórios no alinhamento de datas centrais em cada mês.

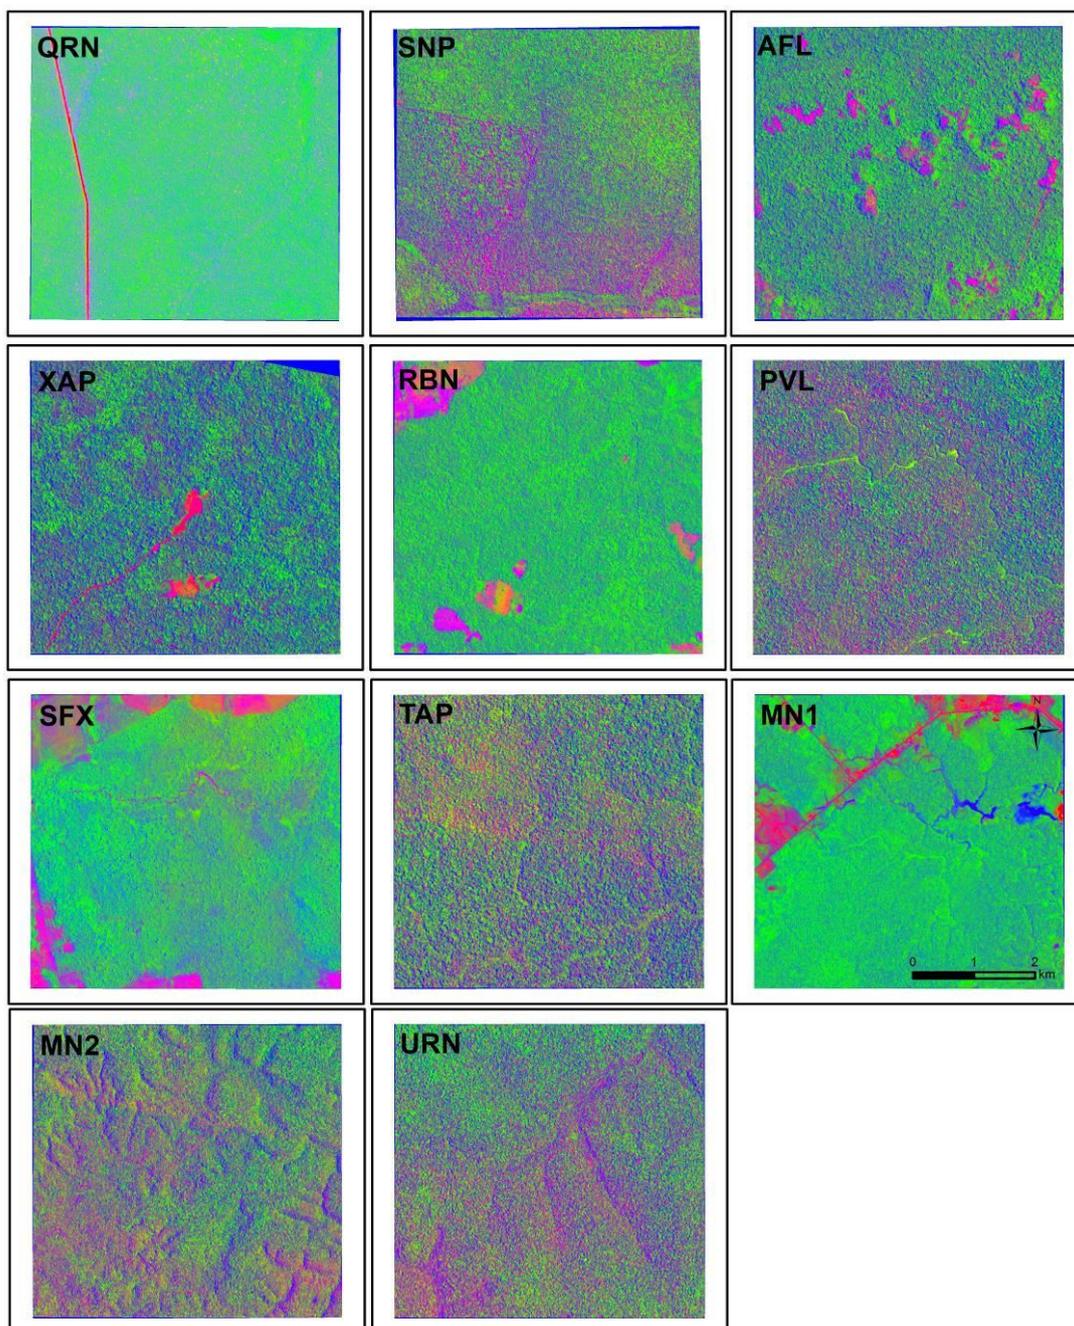
Figura 4.24 - *Endmembers* selecionados para compor o MLME a partir de dados PS.



Fonte: Elaborado pelo autor.

Baseado nos resultados também insatisfatórios para a avaliação de textura, descartou-se essa área de estudo na etapa de análise do MLME. Considerando os demais sítios, áreas como MN2 e URN possuem maiores variações em feições topográficas do que as demais áreas (Figura 4.25). Sítios como QRN possuem uma vegetação mais homogênea, em termos de fração vegetação verde do que os demais. Há sítios também com distribuição mais heterogênea das frações vegetação verde (GV) e solo/vegetação não fotossinteticamente ativa em junho, como indicado pela predominância de cores verde e vermelho nas imagens de SNP, PVL e TAP, algumas das quais afetadas por distúrbios.

Figura 4.25 - Imagens do MLME em composição colorida para dados PS obtidos em junho. A composição RGB foi obtida com as frações solo/NPV, vegetação verde e sombra, respectivamente.

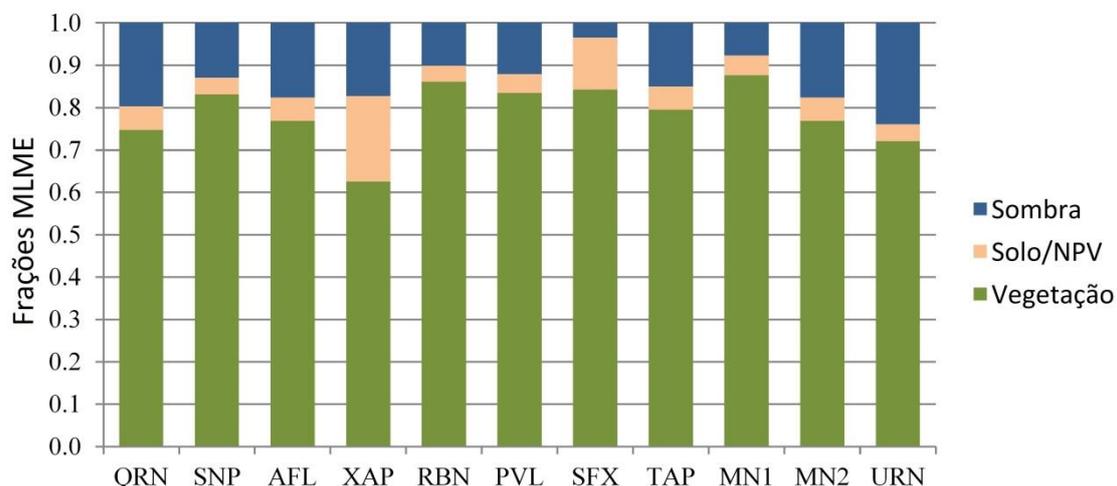


A exemplo da diversidade de alvos vista em MN1, áreas não vegetadas como água e regiões ocupadas aparecem em azul e vermelho, respectivamente. Nenhuma amostragem foi realizada fora de áreas de floresta.

Fonte: Elaborado pelo autor.

Ainda com o propósito de compreender a distribuição de cada fração para cada área de estudo, a Figura 4.26 apresenta a composição entre as três frações para o mês de junho. Nesse contexto, porém, áreas com qualquer uso do solo, feição de água ou significativamente diferentes de florestas tropicais já se encontravam filtradas. Os resultados, portanto, representam possíveis amostras de áreas verdes, sombreadas ou de matéria seca/efeitos de fundo significativos no dossel. É possível observar que a área com menor cobertura da fração vegetação foi XAP, que também apresentou a maior fração solo/matéria seca. Enquanto isso, MN1 se destacou como a área de estudo com maior cobertura da fração vegetação. A área com maior quantidade de sombras foi URN, com destaque para a possível influência de efeitos de fundo de áreas inundadas, devido às características naturais do tipo de floresta dessa área. A menor quantidade de sombras foi detectada em SFX. Esta comparação entre áreas e frações deve ser vista com cuidado, visto que um conjunto diferente de *endmembers* foi utilizado em cada sítio.

Figura 4.26 - Composição total entre frações vegetação verde, solo/matéria seca e sombra para onze áreas de estudo em junho.



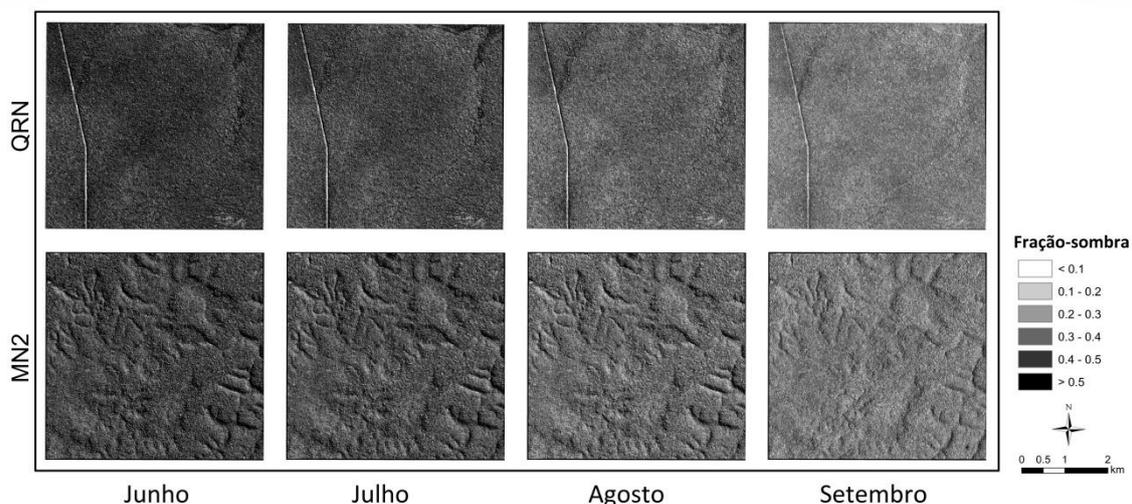
Dados centrais no mês de junho, utilizados para a composição dos *endmembers*, são as representadas na figura. A área STQ foi descartada por não conter dados viáveis.

Fonte: Elaborado pelo autor.

Durante a estação seca, no entanto, é importante observar a variação temporal relativa da fração MLME mais importante em estudos de iluminação solar: a fração-sombra. Tais variações envolvem contribuições de sombras tanto da vegetação, quanto do terreno. Sequências temporais das imagens frações-sombra derivadas do MLME aplicado à reflectância de superfície das áreas de estudo MN2 e QRN são apresentadas na Figura 4.27. Em cada área de estudo, utilizou-se *endmembers* fixos, selecionados em junho pelo algoritmo SMACC, presente no software ENVI, para gerar as imagens.

Ao visualizar as imagens de frações-sombra entre junho e setembro para as áreas QRN e MN2 no ano de 2018 (Figura 4.27), pode-se perceber a diminuição de sombra do início para o final da estação seca. Isso se deve, conforme discutiu-se anteriormente, à mudança principalmente no AZS e, também, no AAS. No final da estação seca, o AZS diminui, gerando uma maior quantidade de energia espalhada na direção da constelação de satélites, que verão, portanto, menos vegetação e terreno sombreados. Nas imagens de MN2, ainda se pode observar um importante fenômeno de variação em direção e intensidade da projeção de feições de terreno. As feições topográficas se tornam menos bem delineadas para os sensores com a diminuição da sombra vista pelos satélites.

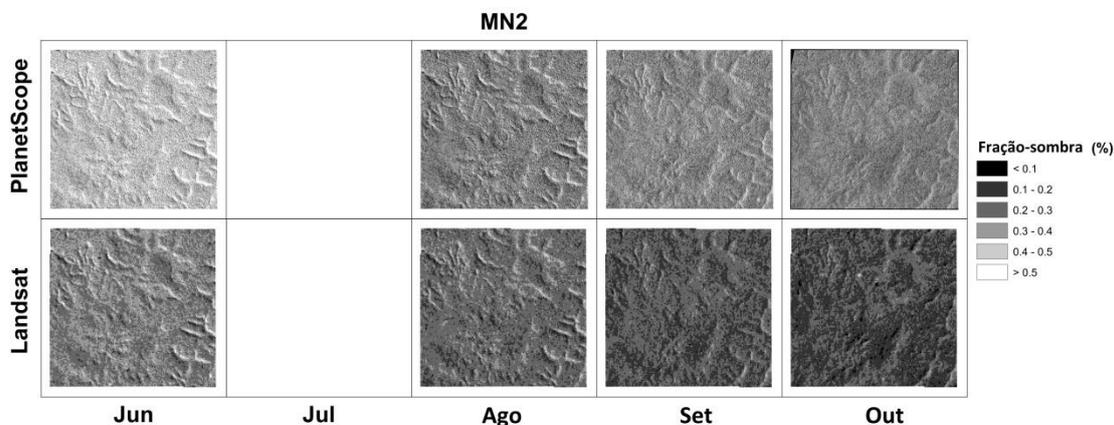
Figura 4.27 - Variações nas imagens frações-sombra PlanetScope do início (junho) para o final (setembro) da estação seca na Amazônia para as áreas de estudo MN2 e QRN.



Fonte: Elaborado pelo autor.

De forma comparativa, especializou-se na Figura 4.28, a variação na composição das frações-sombra para a área de estudo QRN, a partir de dados PS e OLI/Landsat-8 para o ano de 2018. O mês de julho, sem observações válidas para o conjunto Landsat-8 neste ano, foi descartado nessa comparação, mas pode ser observado na Figura 4.25 para os dados PS. Na estação seca, julho e setembro são os meses com valores extremos de AZS. Novamente, para ambos os sensores, é possível identificar a redução nas sombras detectadas por cada MLME do início para o final da estação seca. As feições de terreno, com variações observáveis em dados PS e com redução de sua projeção do início para o final da estação seca neste caso, são observadas visualmente com menos detalhe no conjunto Landsat de dados com resolução espacial de 30 m.

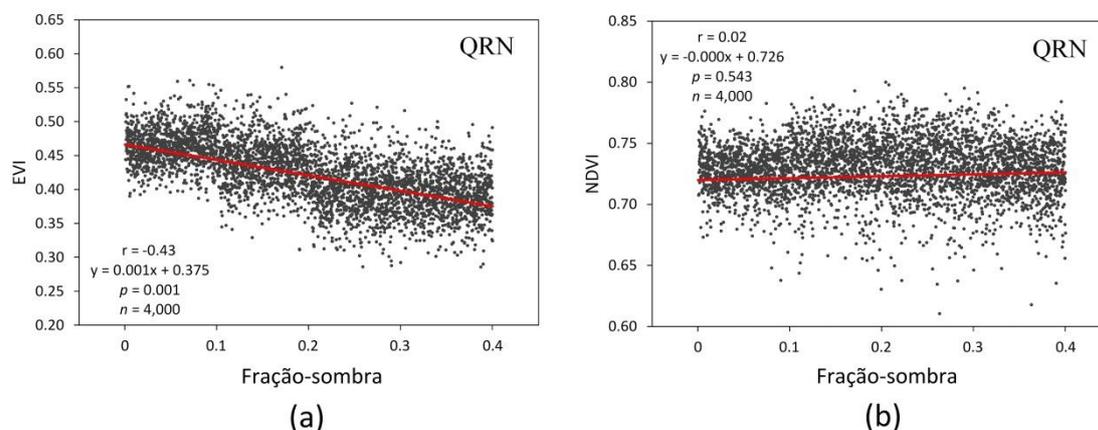
Figura 4.28 - Variações nas imagens frações-sombra PlanetScope e OLI/Landsat-8 do início (junho) para o final (setembro) da estação seca na Amazônia para as áreas de estudo MN2. Resultados para julho foram omitidos devido a ausência de observações válidas.



Fonte: Elaborado pelo autor.

As Figuras 4.29a e 4.29b mostram o comportamento mais anisotrópico do EVI, quando comparado com o do NDVI, aos efeitos de iluminação solar na área QRN. A anisotropia é expressa pelas correlações destes IVs com as frações-sombra. Por exemplo, o EVI foi inversamente correlacionado às frações-sombra na área QRN ( $r = -0.43$  na Figura 4.29a), enquanto o NDVI não mostrou correlação significativa na mesma área ( $r = +0.02$  na Figura 4.29b). Esses resultados corroboram com os resultados descritos anteriormente.

Figura 4.29 - Correlações das frações-sombra do PS com valores de (a) EVI e (b) NDVI.

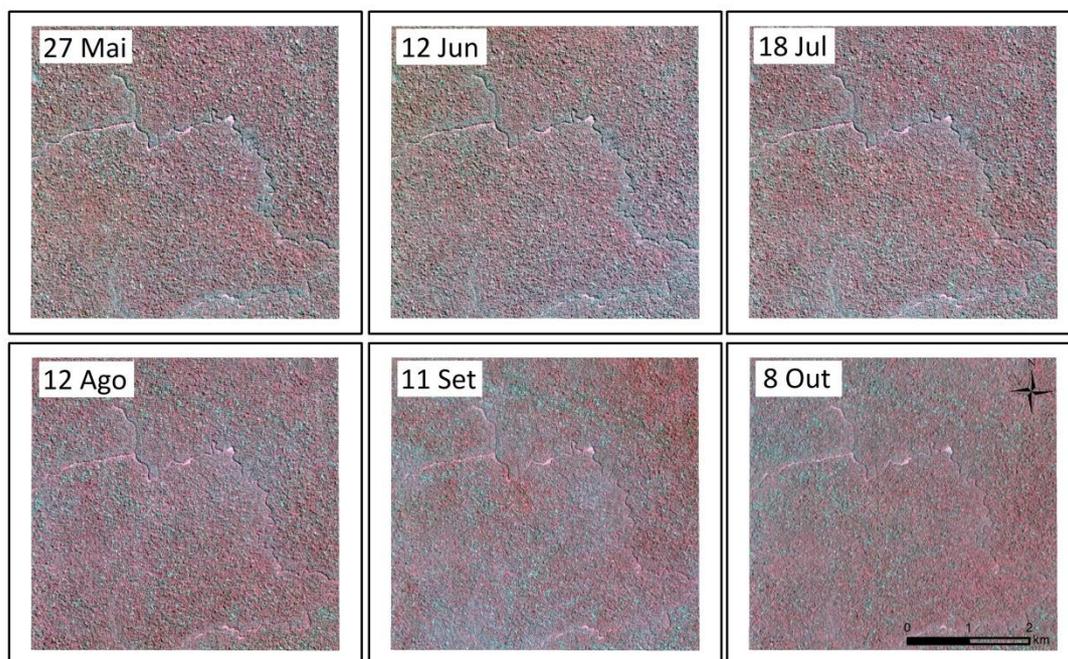


Os resultados foram obtidos na área de estudo QRN utilizando o modelo linear de mistura espectral aplicado aos dados PlanetScope, em reflectância de superfície, obtidos entre junho e setembro (1.000 pixels por data).

Fonte: Elaborado pelo autor.

A observação das alterações em frações-sombra para os dados PS, assim como as observações de alteração em textura das imagens tanto em média quanto em variância, foi comprovada adicionalmente usando composições coloridas PS (Figura 4.30). A Figura 4.28 mostra uma sequência mais abrangente de composições coloridas PS (bandas 432 em RGB, respectivamente), considerando o período de maio a outubro para a área de estudo PVL. Mesmo sem extrair métricas espaciais, é possível observar a uniformização da cena (reflectância e textura) em direção a setembro e outubro, produzida pela diminuição na quantidade de sombras vistas pelos CubeSats no final da estação seca com a diminuição do AZS.

Figura 4.30 - Representação de imagens PS em composição falsa-cor usando as bandas 4(R)3(G)2(B) para a área de estudo PVL entre maio e outubro de 2019.

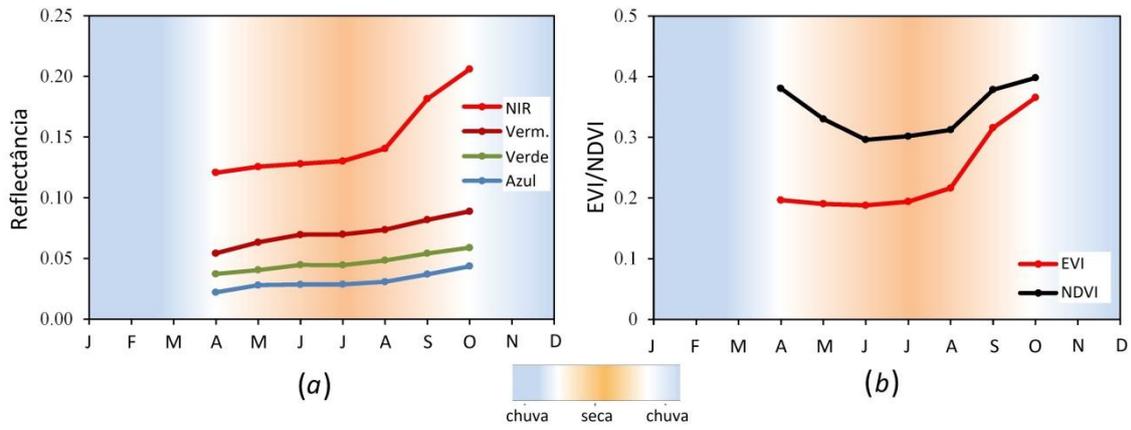


De maio a outubro, é possível observar a uniformização da cena, que se torna mais clara e menos rugosa, devido à diminuição na quantidade de sombras vistas pela constelação de satélites no final da estação seca com a diminuição do AZS.

Fonte: Elaborado pelo autor.

Finalmente, com o propósito de separar os efeitos de iluminação solar da fenologia da vegetação, observou-se o comportamento sazonal de um alvo composicionalmente estável em um curto período de tempo (solo). Dessa forma, mesmo que em uma observação pontual, foram selecionados pixels de solo exposto na área de estudo QRN, a área mais ao sul e, portanto, com maior sazonalidade na iluminação solar representada pelo AZS (Figura 4.31). Foi possível observar a existência de significativa sazonalidade tanto dos IVs (EVI e NDVI), quanto nas quatro bandas espectrais dos dados PS. Novamente, o comportamento do EVI (em vermelho em (a)) foi semelhante ao observado para o NIR (em vermelho em (b)).

Figura 4.31 - Comportamento sazonal de pixels de solo exposto para a área de estudo QRN para (a) azul, verde, vermelho e NIR para dados PS obtidos em todo o ano de 2018; e (b) EVI e NDVI.



Fonte: Elaborado pelo autor.

## 5 DISCUSSÃO

Os resultados desse estudo confirmaram a existência de efeitos de iluminação solar na aquisição de imagens PS de alta resolução espacial durante a estação seca na Amazônia. Tais efeitos, observados pelo aumento crescente da reflectância das bandas PS e de uma diminuição concomitante da fração-sombra em direção ao final da estação seca, foram tipicamente observados em florestas tropicais ombrófilas. Nesse ambiente, tais efeitos se destacam por conta da baixa variabilidade do sinal fenológico capturado em alta resolução espacial e temporal pela constelação de satélites PS. Em alta resolução espacial, além do sombreamento oriundo do dossel, efeitos de iluminação solar do terreno também contribuem para a proporção da fração-sombra obtida a partir dos MLME, especialmente em áreas com feições topográficas visíveis nas cenas.

O SZA decrescente e o AAS crescente do início (junho) para o final (setembro) da estação seca produziram mudanças no brilho da vegetação, na textura das imagens, e nas frações-sombra em doze áreas de estudo imageadas pela constelação de satélites PS entre 2017 e 2019. A amplitude do SZA na estação seca aumentou do norte para o sul do bioma, enquanto a amplitude do SAA aumentou do sul para o norte da mesma região. Ambos os fatores contribuíram para o aumento do espalhamento da energia incidente sobre o dossel e para o decréscimo de suas sombras vistas pelos CubeSats no final da estação seca. As modificações nas condições de iluminação das cenas produziram também mudanças na textura das imagens dos dados com resolução espacial de 3,7 m.

A análise sem precedentes da série temporal PS sobre as doze áreas de estudo na Amazônia, a partir de 493 imagens adquiridas entre 2017 e 2019, mostrou que a iluminação solar afetou diferentemente a determinação do EVI, tendo um impacto menor no cálculo do NDVI. Por causa do aumento generalizado de reflectância, tanto na banda do vermelho, quanto na banda do NIR, tais efeitos foram normalizados durante o cálculo do NDVI. Em contraste, por causa da grande influência da reflectância do NIR na determinação do EVI (GALVÃO et al., 2011; SAMANTA et al., 2012), efeitos de iluminação solar

contribuíram para o aumento do sinal deste índice de vegetação ao final da estação seca. Portanto, os resultados do presente trabalho com dados PS confirmaram a maior anisotropia do EVI, quando comparado ao NDVI, como previamente reportado na literatura (SIMS et al., 2011; MOURA et al., 2012). Demonstrou-se neste trabalho, comparativamente, a maior sensibilidade do EVI aos efeitos de iluminação solar, conforme indicado pelas correlações desse índice com os ângulos solares (SZA e SAA), com o atributo média da textura, e com as frações-sombra. Essas correlações não foram estatisticamente significantes para o NDVI. O EVI também foi mais sensível a sombras provenientes de iluminação do terreno do que o NDVI, como previamente demonstrado em estudos de efeitos topográficos feitos por Matsushita et al. (2007), Galvão et al. (2016) e Oliveira et al. (2019). Os resultados dessa tese corroboram com observações anteriores que mostraram a importância de se considerar efeitos de iluminação em análises de séries temporais utilizando IVs, incluindo aqueles causados por modificações temporais na órbita dos satélites Landsat-5 e *Earth Observing One* (EO-1) (ZHANG; ROY, 2016; GALVÃO et al., 2019).

De um ponto de vista de fenologia da vegetação, a presente análise de dados da constelação de satélites PS indica a necessidade de cuidado na interpretação de sinais biofísicos de verdejamento reportados em ampla escala na Amazônia, mesmo quando dados de sensoriamento remoto são adquiridos com visada ao nadir. Mais especificamente, quando IVs anisotrópicos como o EVI forem utilizados na análise, a correção dos efeitos de iluminação solar e, em uns poucos casos, de terreno, se faz necessária para o devido uso de tais dados em estudos a partir de dados de sensores orbitais para a Amazônia quando investigadas tendências sazonais.

Estudos de fenologia da vegetação, usando observações de torres de fluxo no leste da Amazônia e dados de uma câmera hiperespectral, mostraram uma diversidade de respostas fenológicas durante a estação seca que foi dependente das espécies da vegetação (MOURA et al., 2017). Por outro lado, na Amazônia central, uma câmera RGB montada em uma torre capturou eventos de brotamento de folhas (*leaf flushing*) que, em geral, acompanharam

a sazonalidade de luz disponível na estação seca (LOPES et al., 2016). Possíveis mudanças no índice de área foliar (IAF) reportadas na literatura como explicação para o comportamento do EVI na estação seca, não foram consistentes com o aumento do NIR e do vermelho no mesmo período para dados PS. Além disso, o índice de área foliar medido a partir de fotografias hemisféricas na área de estudo QRN não apresentou mudanças significativas durante a estação seca (GALVÃO et al., 2011). Na realidade, mudanças na reflectância do NIR podem ser também causadas por modificações na estrutura do dossel ou na distribuição angular das folhas, fatores que não foram avaliados neste estudo.

Nos estudos de Lopes et al. (2016) e Moura et al. (2017), os valores correspondentes de EVI MODIS, corrigidos para efeitos BRDF, mostraram um pequeno incremento em direção ao final da estação seca que não foi capturado pelo NDVI. Na análise dos dados PS do presente trabalho, o padrão predominante observado no final da estação seca para a maioria das áreas foi de fato uma pequena diminuição do NDVI com o aumento do déficit hídrico em direção a setembro, mas com variações dentro dos intervalos de confiança apresentados. Petri et al. (2019) encontraram mudanças de 5% no NDVI e 60% de mudanças no EVI para a maior parte da Amazônia antes da correção de efeitos bidirecionais do MODIS. Assumindo uma correção precisa desses efeitos, as diferenças de EVI no período seco diminuiriam para valores próximos a 0.02%.

Outros estudos, como o de Morton et al. (2014), capturaram um sinal aproximadamente constante do EVI durante a estação seca após correção BRDF. Adicionalmente aos eventos de *leaf flushing*, que ocorrem predominantemente nos meses de maior insolação (LOPES et al., 2016), outra possível explicação biofísica para o sinal residual do EVI após correção BRDF foi dada por Wu et al. (2016) e Moura et al. (2017). Nesses trabalhos, os autores associaram esse pequeno incremento no EVI em direção ao final da estação seca às modificações no IAF de folhas maduras através de um modelo de demografia foliar. No trabalho de Moura et al. (2017), o EVI, como um índice essencialmente estrutural, acompanhou as mudanças na proporção de folhas

maduras, que foi aproximadamente consistente com o comportamento sazonal do índice *Green-Red Normalized Difference* (GRND). No presente estudo, não se considerou o GRND na análise por conta do resultado inesperado de obtenção de valores negativos sobre vegetação verde. Conforme reportado por Breunig et al. (2020), o problema provavelmente está associado com a sobreposição (*overlapping*) das funções de resposta das bandas do verde e do vermelho nos dados da primeira geração da constelação PS. Aparentemente, este problema deixou de existir nas gerações mais novas de dados PS como as do SuperDove (BREUNIG et al., 2020).

A compreensão de mudanças na reflectância espectral das bandas PS causadas por ambos os fenômenos (*leaf flushing* e demografia de folhas) ainda requer estudos adicionais de espectroscopia de reflectância e observações de campo para entender as modificações espectrais resultantes nos intervalos do NIR e do visível. Entretanto, se estes eventos existirem, sua resposta espectral capturada pelo EVI está acoplada com efeitos de iluminação solar e de terreno, especialmente em dados não corrigidos para os efeitos bidirecionais.

Como outra contribuição original do presente trabalho, demonstrou-se que a geração de séries temporais densas de IVs, obtidas a partir de dados de alta resolução espacial e temporal de constelações de satélites, é possível para estudar a fenologia das florestas tropicais da Amazônia. Mais especificamente, a revisita diária possibilita a criação de tais séries e contorna, principalmente durante a estação seca e períodos adjacentes, a persistente cobertura de nuvens em diferentes partes do bioma. O uso de tais dados traz uma escala sem precedentes de observações fenológicas para essa região. A partir das melhorias em resolução espectral recentemente adotadas para os dados de constelação de satélites da Planet, novos IVs com diferentes significados biofísicos serão calculados e comparados para adicionar confiabilidade às observações fenológicas. Por conta das dimensões continentais do bioma amazônico, os resultados deste trabalho indicaram a necessidade de correção para efeitos de iluminação solar antes de efetivar estudos de fenologia da vegetação em larga escala utilizando índices anisotrópicos como o EVI.

Alternativamente, o uso de IVs como o NDVI, operando com diferenças normalizadas de pares de bandas, podem resolver esse problema.

Apesar da capacidade de adquirir imagens diárias sobre a Amazônia, a persistente cobertura de nuvens ainda é um problema na análise dos dados, especialmente durante a estação chuvosa. Essa característica gerou, na prática, séries temporais com espaçamentos diferentes nas doze áreas de estudo selecionadas: uma para a estação chuvosa e outra para a estação seca. Procedimentos mais elaborados de filtragem de nuvens podem e devem, no futuro, ser desenvolvidos para preencher essas lacunas nas séries temporais. Estes procedimentos facilitarão o uso de algoritmos para obter informação fenológica de séries temporais mais densas geradas para as florestas tropicais da Amazônia a partir de dados PS. Esses algoritmos, ainda, deverão considerar a baixa variabilidade do sinal fenológico capturado pelos satélites sobre as florestas tropicais da Amazônia, quando comparada, por exemplo, com a variabilidade vista no Cerrado. Essas questões deverão ser tratadas em estudos futuros.

Finalmente, mesmo que em caráter comparativo, foi possível observar as mesmas tendências de anisotropia do EVI, isotropia do NDVI, modificações em textura e frações-sombra também para dados OLI/Landsat-8 durante esse estudo, mesmo com a agregação parcial dos efeitos de sombra em dados de média resolução espacial (30 m). Impossibilitada pelo tempo de revisita de 16 dias, intrínseco do sensor, e mesmo com seus efeitos suavizados pela resolução espacial mais baixa, de 30 metros, os dados Landsat indicaram que, em um estudo de caso com foco na transição de escalas em múltiplas regiões da Amazônia, os resultados observados podem ser altamente correlacionados com dados de alta resolução espacial de constelações de satélites. Estudos com foco na detecção de eventos de *blowdowns* na Amazônia central, utilizando esses dois conjuntos de dados, também observaram uma melhor formação de séries temporais a partir dos dados PS, mesmo que a análise a partir do OLI/Landsat-8 seja factível (PING et al., 2023). Ainda, com o foco na transição de escalas espaciais, os possíveis efeitos da suavização de efeitos topográficos do terreno e espalhamento do dossel devem ser mensurados,

adicionando importante contribuição para a compreensão do sinal residual do EVI em estudos de fenologia em larga escala para florestas tropicais da Amazônia.

Em resumo, se IVs anisotrópicos como o EVI forem considerados em estudos de fenologia de vegetação na Amazônia usando dados de alta resolução espacial do PS, a correção dos efeitos de iluminação solar e, em uns poucos casos (áreas com relevo acidentado), de iluminação do terreno (correção topográfica), é altamente recomendável para a obtenção precisa de métricas fenológicas sobre as florestas tropicais. Estas etapas aparentemente não são necessárias ao se utilizar IVs que utilizam diferenças normalizadas entre pares de bandas em suas formulações (p.ex., NDVI). No caso do EVI, é possível que um ajuste nos parâmetros utilizados em sua equação para a correção dos efeitos do solo (fator L) diminua a sensibilidade deste índice para efeitos bidirecionais, conforme sugerido por Galvão et al. (2011).

## 6 CONCLUSÕES

Os resultados deste estudo mostraram a existência de efeitos de iluminação solar na aquisição de imagens PS durante a estação seca na Amazônia, especialmente sobre a determinação do EVI. Os efeitos de iluminação solar e do terreno tendem a ser realçados com a alta resolução espacial de aquisição das imagens da constelação de satélites. Do início para o final da estação seca, o AZS diminuiu e o AAS aumentou, afetando as proporções relativas de espalhamento da energia incidente no dossel e de suas sombras projetadas na direção da constelação de satélites PS. A amplitude do AZS entre junho e setembro foi maior no sul da Amazônia, mas o contrário foi observado para a amplitude do SAA. Efeitos de iluminação solar mudaram o brilho da vegetação ao longo do tempo devido ao aumento generalizado da reflectância nas bandas PS em direção a setembro, modificação que foi também detectada pela ACP. Os efeitos de iluminação solar afetaram a textura das imagens, com a média da textura GLCM aumentando e a variância da textura diminuindo em direção ao final da estação seca. Por conta da redução em sombras no dossel detectadas por dados PS em setembro, frações-sombra do MLME também diminuiram de junho para setembro. Esses resultados, em certa medida, foram replicados por análises pareadas a partir de dados OLI/Landsat-8, reforçando a existência de tal comportamento sazonal em dados obtidos ao nadir, mesmo ao considerar resoluções espaciais diferentes (alta de 3,7 m do PS e média de 30 m do Landsat).

Em resposta aos efeitos de iluminação solar, o EVI foi mais anisotrópico do que o NDVI. Efeitos de iluminação solar foram compensados no cálculo do NDVI, visto que estes efeitos causaram um aumento de reflectância tanto na banda do vermelho, quanto na banda do NIR. Em contraste, esses efeitos aumentaram o sinal do EVI PS ao final da estação seca por causa da grande dependência desse índice não normalizado, formulado a partir de três bandas, da resposta espectral da banda do NIR. Como outra evidência da anisotropia, o EVI apresentou maiores correlações com os ângulos solares e com as frações-sombra do que aquelas observadas para o NDVI. Os resultados obtidos com o

PS (IVs, métricas de textura e frações-sombra) foram consistentes com os observados usando dados Landsat.

Quanto às questões de pesquisa colocadas na seção introdutória deste trabalho, pode-se fazer as seguintes considerações:

(a) Qual é o comportamento de atributos espectrais, como a reflectância de superfície e índices de vegetação (IVs), durante a estação seca em dados da constelação de satélites PS, adquiridos em uma geometria de visada ao nadir? Ainda, conectando a essa primeira questão, dentro de janelas de observação possíveis, é viável reproduzir os resultados obtidos com dados PS para observações em dados Landsat?

Em relação a esta questão, observou-se uma tendência de aumento do brilho, corroborada pela ACP, pela reflectância e também pelo EVI (anisotrópico) mesmo com a coleta de dados ao nadir. Foi possível reproduzir os resultados obtidos a partir de imagens Landsat também, porém a baixa revisita e a frequente cobertura de nuvens não permitiram uma análise mais profunda utilizando os mesmos métodos.

(b) Existem efeitos de iluminação solar que afetem diferentemente a determinação do NDVI e do EVI ao longo da estação seca?

Os resultados mostraram que os efeitos de iluminação solar e do terreno foram mais fortes sobre a determinação do EVI e foram pouco importantes sobre o cálculo do NDVI. Este último IV compensou tais efeitos usando diferenças normalizadas entre as bandas do vermelho e do NIR em sua formulação.

(c) Existem variações na quantidade de sombras observadas por dados PS, produzindo modificações na textura das imagens do início para o final da estação seca?

Os resultados do MLME mostram que os valores das frações-sombras capturadas por dados PS tendem a diminuir na direção do final da estação seca. De forma consistente, as métricas GLCM de média e variância de textura aumentaram e diminuíram, respectivamente, em direção a setembro. Em alguns casos, as diferenças de textura foram aparentes em composições

coloridas falsa-cor que mostraram superfícies mais brilhantes ou menos rugosas em direção a setembro.

Os resultados obtidos ressaltam a importância de corrigir efeitos de iluminação solar sempre que IVs anisotrópicos como o EVI forem utilizados para estudos de fenologia em larga escala nas florestas tropicais da Amazônia. Isto é especialmente importante na análise de séries temporais de alta resolução espacial e temporal geradas pela constelação de satélites PS. Em trabalhos futuros, a transição de escalas entre dados de alta resolução espacial, como os PS, e dados de média resolução espacial, como os do Landsat, deve ser abordada com profundidade para ampliar a compreensão dos efeitos da agregação da sombra no pixel, conforme a escala espacial se degrada.

Além disso, o aumento do número de bandas na terceira geração da constelação de satélites PS, intitulada SuperDove, com oito bandas espectrais, ampliará a possibilidade de novos estudos com novos IVs. A análise combinada dos mesmos, considerando suas diferentes sensibilidades para efeitos de iluminação solar e a comparação de seus perfis sazonais, poderá ser importante para a obtenção mais precisa de métricas fenológicas sobre florestas tropicais da Amazônia.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, C. T.; GALVAO, L. S.; OMETTO, J. P. H. B.; JACON, A. D.; PEREIRA, F. R. S.; SATO, L. Y., LONGO, M. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, v.232, e111323, 2019.

ANDERSON, L. O.; ARAGÃO, L. E. O. C.; LIMA, A. D.; SHIMABUKURO, Y. E. Burn scar detection based on linear mixture model and vegetation indices using multitemporal data from MODIS/ TERRA sensor in Mato Grosso State, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 4, p.445-456, 2005.

ANDERSON, L. O.; MALHI, Y.; ARAGÃO, L. E.; LADLE, R.; ARAI, E.; BARBIER, N.; PHILLIPS, O. Remote sensing detection of droughts in Amazonian forest canopies. **New Phytologist**, v. 187, n. 3, p. 733-750, 2010.

ASNER, G. P.; KELLER, M.; PEREIRA JUNIOR, R.; ZWEEDE, J. C.; SILVA, J. N. Canopy damage and recovery after selective logging in Amazonia: field and satellite studies. **Ecological Applications**, v. 14, n. 4, p. 280-298, 2004.

ARAGÃO, L. E. O.; MALHI, Y.; ROMAN-CUESTA, R. M.; SAATCHI, S.; ANDERSON, L. O.; SHIMABUKURO, Y. E. Spatial patterns and fire response of recent Amazonian droughts. **Geophysical Research Letters**, v. 34, n. 7, 2007.

ARAÚJO, V. C. **Fenologia de essências florestais Amazônicas**. 4 ed. Belém: INPA, 1970. 27 p. Disponível em: <https://repositorio.inpa.gov.br/handle/1/37912>.

ATKINSON, P. M.; DASH, J.; JEGANATHAN, C. Amazon vegetation greenness as measured by satellite sensors over the last decade. **Geophysical Research Letters**, v. 38, n. 19, 2011.

BENDINI, H. N. **Agricultural land classification based on phenological information from dense time-series Landsat-like images in the Brazilian Cerrado**. 2018. 96 p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

BENDINI, H. N.; FONSECA, L. M. G.; SCHWIEDER, M.; KÖRTING, T. S.; RUFIN, P.; SANCHES, I. D.; HOSTERT, P. Detailed agricultural land classification in the Brazilian cerrado based on phenological information from dense satellite image time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, e 101872, 2019.

BERRA, E. L.; GAULTON, R.; BARR, S. Assessing spring phenology of a temperate woodland: a multiscale comparison of ground, unmanned aerial vehicle and Landsat satellite. **Remote Sensing of Environment**, v. 223, p. 229 - 242, 2019.

BHANDARI, S.; PHINN, S.; GILL, G. Assessing viewing and illumination geometry effects on the MODIS vegetation index (MOD13Q1) time series: implications for monitoring phenology and disturbances in forest communities in Queensland, Australia. **International Journal of Remote Sensing**, v. 32, n. 22, p. 7513-7538, 2011.

BAJOCCO, S.; FERRARA, C.; ALIVERNINI, A.; BASCIETTO, M.; RICOTTA, C. Remotely-sensed phenology of Italian forests: Going beyond the species. **International Journal of Applied Earth Observation and Geoinformation**, v. 74, p. 314-321, 2019.

BOURSCHEIDT, V.; BREUNIG, F. M.; BALBINOT, R.; ERTHAL, D. A.; DAL OSTO, J.; FERLA, A. K. Cálculo das variações de índices de vegetação com cenas PlanetScope adquiridas no mesmo dia e efeito sobre a análise de séries temporais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 20., 2023, Florianópolis. **Anais...** São José dos Campos: INPE, 2023.

BRANDO, P. M.; GOETZ, S. J.; BACCINI, A.; NEPSTAD, D. C.; BECK, P. S.; CHRISTMAN, M. C. Seasonal and interannual variability of climate and vegetation indices across the Amazon. **Proceedings of the National Academy of Sciences**, v. 107, n. 33, p.14685-14690, 2010.

BREUNIG, F. M.; GALVÃO, L. S.; DALAGNOL, R.; DAUVE, C. E.; PARRAGA, A.; SANTI, A. L.; CHEN, S. Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, v.85, e102004, 2020.

CÂMARA, G.; VALERIANO, D. M.; SOARES, J. V. **Metodologia para o Cálculo da Taxa Anual de Desmatamento na Amazônia Legal**. São José dos Campos: INPE, 2013. 37 p. Disponível em: [http://www.obt.inpe.br/prodes/metodologia\\_TaxaProdes.pdf](http://www.obt.inpe.br/prodes/metodologia_TaxaProdes.pdf).

CERNY, B. A.; KAISER, H. F. A study of a measure of sampling adequacy for factor-analytic correlation matrices. **Multivariate Behavioral Research**, v. 12, n. 1, p.43-47, 1977.

CHENG, Y.; VRIELING, A.; FAVA, F.; MERONI, M.; MARSHALL, M.; GACHOKI, S. Phenology of short vegetation cycles in a Kenyan rangeland from PlanetScope and Sentinel-2. **Remote Sensing of Environment**, v. 248, e112004, 2020.

EKLUNDH, L. R. Noise estimation in NOAA AVHRR Maximum-Value composite NDVI images. **International Journal of Remote Sensing**, v. 16, n. 15, p. 2955-2962, 1995.

FICK, S. E.; HIJMANS, R. J. Worldclim 2: new 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, 2017.

FRIEDL, M.; GRAY, J.; SULLA-MENASHE, D. **MCD12Q2 MODIS/Terra+Aqua land cover dynamics yearly L3 global 500m SIN grid V006 data set**. Washington: NASA, 2015.

FROLKING, S.; MILLIMANA, T.; PALACEA, M.; WISSERA, D.; LAMMERSA, R.; FAHNESTOCKA, M. Tropical forest backscatter anomaly evident in SeaWinds scatterometer morning overpass data during 2005 drought in Amazonia. **Remote Sensing of Environment**, v. 115, n. 3, p. 897–907, 2011.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. **Scientific Data**, v. 66, 2015.

GALVÃO, L. S.; BREUNIG, F. M.; TELES, T. S.; GAIDA, W.; BALBINOT, R. Investigation of terrain illumination effects on vegetation indices and VI-derived phenological metrics in subtropical deciduous forests. **GIScience & Remote Sensing**, v. 53, n. 3, p. 360-381, 2016.

GALVÃO, L. S.; SOUZA, A. A.; BREUNIG, F. M. A hyperspectral experiment over tropical forests based on the EO-1 orbit change and PROSAIL simulation, **GIScience & Remote Sensing**, v. 57, n.1, p. 74-90, 2020.

GALVÃO, L. S.; SANTOS, J. R.; ROBERTS, D. A.; BREUNIG, F. M.; TOOMEY, M.; MOURA, Y. M. On intra-annual EVI variability in the dry season of tropical forest: A case study with MODIS and hyperspectral data. **Remote Sensing of Environment**, v. 115, n. 9, p. 2350-2359, 2011.

GATTI, L. V.; BASSO, L. S.; MILLER, J. B.; GLOOR, M.; GATTI DOMINGUES, L.; CASSOL, H.; TEJADA, G.; ARAGÃO, L.; NOBRE, C.; PETERS, W.; MARANI, L.; ARAI, E.; SANCHES, A. H.; CORRÊA, S. M.; ANDERSON, L.; VON RANDOW, C.; CORREIA, C.; CRISPIM, S. P.; NEVES, R. Amazonia as a carbon source linked to deforestation and climate change. **Nature**, v. 595, n. 7867, p. 388–393, 2021.

GRUNINGER, J. H.; RATKOWSKI, A. J.; HOKE, M. L. The sequential maximum angle convex cone (SMACC) endmember model. In: ALGORITHMS AND TECHNOLOGIES FOR MULTISPECTRAL, HYPERSPECTRAL, AND ULTRASPECTRAL IMAGERY, 10., 2004. **Proceedings...** SPIE, 2004. v. 5425.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973.

HALL-BEYER MRYKA, P. D. GLCM texture: a tutorial. In: INTERNATIONAL SYMPOSIUM ON BALLISTICS, 17., 2017. **Proceedings...** 2017. p. 18–19.

HENDERSON-SELLERS, A. Defogging cloud determination algorithms. **Nature**, v. 298, p. 419 – 420, 1982.

HILKER, T.; GALVÃO, L. S.; ARAGÃO, L. E. O. C.; MOURA, Y. M.; AMARAL, C. H.; LYAPUSTIN, A. I.; WU, J.; ALBERT, L. P.; FERREIRA, M. J.; ANDERSON, L. O.; SANTOS, V. A. H. F.; PROHASKA, N.; TRIBUZY, E.; CERON, J. V. B.; SALESKA, S. R.; WANG, Y.; GONÇALVES, J. F. C.; OLIVEIRA-JUNIOR, R. C.; RODRIGUES, J. V. F. C.; GARCIA, M. N. Vegetation chlorophyll estimates in the Amazon from multi-angle MODIS observations and canopy reflectance model. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, p. 278-287, 2017.

HOUBORG, R.; MCCABE, M. F. A cubesat enabled spatio-temporal enhancement method (cestem) utilizing planet, landsat and modis data. **Remote Sensing of Environment**, v. 209, p. 211-226, 2018.

HUETE, A. R.; DIDAN, K.; SHIMABUKURO, Y. E.; RATANA, P.; SALESKA, S. R.; HUTYRA, L. R.; MYNENI, R. Amazon rainforests green-up with sunlight in dry season. **Geophysical Research Letters**, v. 33, n. 6, 2006.

IRISH, R. R.; BARKER, J. L.; GOWARD, S. N.; ARVIDSON, T. Characterization of the Landsat-7 ETM + automated cloud-cover assessment (ACCA) algorithm. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 10, p.1179-1188, 2006.

IRISH, R. Landsat-7 automatic cloud cover assessment algorithms for multispectral, hyperspectral, and ultraspectral imagery. **The International Society for Optical Engineering**, v. 4049, p. 348–355, 2000.

JÍMENEZ-MUÑOZ, J.C.; MATTAR, C.; BARICIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J.A.; SCHRIER, G. Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015–2016. **Scientific Reports**, v. 6, e33130, 2016.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**, v. 15, n.3, p.259-263, 2006.

LYAPUSTIN, A. I.; WANG, Y.; LASZLO, I.; HILKER, T.; HALL, F. G.; SELLERS, P. J.; TUCKER, C. J.; KORKIN, S. V. Multi-Angle Implementation of Atmospheric Correction for MODIS (MAIAC): 3. atmospheric correction. **Remote Sensing of Environment**, v. 127, p. 385-393, 2012.

LYAPUSTIN, A. I.; WANG, Y.; LASZLO, I.; KAHN, R.; KORKIN, S.; REMER, L.; LEVY, R.; REID, J. S. Multiangle Implementation of Atmospheric Correction (MAIAC): 2. aerosol algorithm. **Journal of Geophysical Research: Atmospheres**, v. 116, n. D3, 2011.

MACHADO, C. B. **Análise fenológica do dossel da floresta nacional do tapajós utilizando dados orbitais do sensor MODIS e hiperespectrais locais**. 2017. 143p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

MALLADI, R. M. V.; NIZAMI, A.; MAHAKALI, M. S. Cloud masking technique for high-resolution satellite data: an artificial neural network classifier using spectral & textural context. **Journal of Indian Society of Remote Sensing**, v. 47, p. 661–670, 2019.

MARENGO, J. A; TOMASELLA, J.; SOARES, W. R.; ALVES, L. M.; NOBRE, C. A. Extreme climatic events in the Amazon basin. **Theoretical and Applied Climatology**, v. 107, n. 1/2, p. 73-85, 2012.

MATSUSHITA, B.; YANG, W.; CHEN, J.; ONDA, Y.; QIU, G. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. **Sensors**, v. 7, n. 11, p. 2636-2651, 2007.

MEIER, G. A.; BROWN, J. F. **Remote sensing of land surface phenology**. Washington: US Geological Survey, 2014.

MELAAS, E. K.; FRIEDL, M. A.; ZHU, Z. Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM+ data. **Remote Sensing of Environment**, v. 132, p. 176-185, 2013.

MELAAS, E. K.; FRIEDL, M. A.; SULLA-MENASHE, D. **Landsat-derived Spring and Autumn Phenology, Eastern US - Canadian Forests, 1984-2013**. [S.I.]: ORNL DAAC, 2018.

MELAAS, E. K.; SULLA-MENASHE, D.; GRAY, J. M.; BLACK, T. A.; MORIN, T. H.; RICHARDSON, A. D.; FRIEDL, M. A. Multisite analysis of land surface phenology in North American temperate and boreal deciduous forests from Landsat. **Remote Sensing of Environment**, v. 186, p. 452-464, 2016.

MONTEIRO, A. L.; SOUZA, C. M.; BARRETO, P. Detection of logging in Amazonian transition forests using spectral mixture models. **International Journal of Remote Sensing**, v. 24, n. 1, p.151-159, 2003.

MORTON, D. C.; NAGOL, J.; CARABAJAL, C. C.; ROSETTE, J.; PALACE, M.; COOK, B. D.; NORTH, P. R. Amazon forests maintain consistent canopy structure and greenness during the dry season. **Nature**, v. 506, n. 7487, p. 221-224, 2014.

MOURA, Y. M.; GALVÃO, L. S.; SANTOS, J. R.; ROBERTS, D. A.; BREUNIG, F. M. Use of MISR/Terra data to study intra-and inter-annual EVI variations in the dry season of tropical forest. **Remote Sensing of Environment**, v. 127, p. 260-270, 2012.

MOURA, Y. M. **Using multi-angle MODIS data to observe vegetation dynamics in the Amazon Forest**. 2015. 107 p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016.

MOURA, Y. M.; GALVÃO, L. S.; HILKER, T.; WU, J.; SALESKA, S.; AMARAL, C. H.; ARAGÃO, L. E. Spectral analysis of amazon canopy phenology during the dry season using a tower hyperspectral camera and modis observations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 52-64, 2017.

MYNENI, R. B.; YANG, W.; NEMANI, R. R.; HUETE, A. R.; DICKINSON, R. E.; KNYAZIKHIN, Y.; SALOMONSON, V. V. Large seasonal swings in leaf area of Amazon rainforests. **Proceedings of the National Academy of Sciences**, v. 104, n. 12, p. 4820-4823, 2007

OLIVEIRA, L. M.; GALVÃO, L. S.; PONZONI, F. J. Topographic effects on the determination of hyperspectral vegetation indices: a case study in southeastern Brazil. **Geocarto International**, v. 36, n. 19, p. 2186-2203, 2021.

PENG, D.; ZHANG, X.; WU, C.; HUANG, W.; GONSAMO, A.; HUETE, A.R.; DIDAN, K.; TAN, B.; LIU, X.; ZHANG, B. Intercomparison and evaluation of spring phenology products using National Phenology Network and AmeriFlux observations in the contiguous United States. **Agricultural and Forest Meteorology**, v. 242, p. 33-46, 2017.

PETRI, C. A.; GALVÃO, L. S. Sensitivity of seven MODIS vegetation indices to BRDF effects during the Amazonian dry season. **Remote Sensing**, v. 11, n. 14, e1650, 2019.

PETRI, C. A.; GALVÃO, L. S.; LYAPUSTIN, A. I. MODIS BRDF effects over Brazilian tropical forests and savannahs: a comparative analysis. **Remote Sensing Letters**, v. 10, n. 2, p. 95-102, 2019.

PING, D.; DALAGNOL, R.; GALVÃO, L. S.; NELSON, B.; WAGNER, F.; SCHULTZ, D. M.; BISPO, P. D. C. Assessing the magnitude of the Amazonian forest blowdowns and post-disturbance recovery using Landsat-8 and Time Series of PlanetScope satellite constellation data. **Remote Sensing**, v. 15, n. 12, e3196, 2023.

PLANET LABS. **Planet imagery product specifications**. [S.l.]: Mountain View, 2022.

QUESADA, C. A.; LLOYD, J.; ANDERSON, L. O.; FYLLAS, N. M.; SCHWARZ, M.; CZIMCZIK, C. I. Soils of Amazonia with particular reference to the RAINFOR sites. **Biogeosciences**, v. 8, n. 6, p. 1415-1440, 2011.

RATHCKE, B.; LACEY, E. P. Phenological patterns of terrestrial plants. **Annual Review of Ecology and Systematics**, v. 16, n. 1, p. 179-214, 1985.

ROBERTS, D. A.; SMITH, M. O.; ADAMS, J. B. Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. **Remote Sensing of Environment**, v. 44, n. 2/3, p. 255-269, 1993.

ROY, D. P.; ZHANG, H. K.; JU, J.; GOMEZ-DANS, J. L.; LEWIS, P. E.; SCHAFF, C. B.; KOVALSKYY, V. A general method to normalize Landsat reflectance data to nadir BRDF adjusted reflectance. **Remote Sensing of Environment**, v. 176, p. 255-271, 2016.

SAKAMOTO, T.; WARDLOW, B.D.; GITELSON, A.A.; VERMA, S.B.; SUYKER, A.E.; ARKEBAUER, T.J. A Two-step filtering approach for detecting maize and soybean phenology with time-series MODIS data. **Remote Sensing of Environment**, v. 114, n. 10, p. 2146-2159, 2010.

SALESKA, S. R.; DIDAN, K.; HUETE, A. R.; ROCHA, H. R. Amazon forests green-up during 2005 drought. **Science**, v. 318, n. 5850, p. 612-612, 2007.

SAMANTA, A.; GANGULY, S.; HASHIMOTO, H.; DEVADIGA, S.; VERMOTE, E.; KNYAZIKHIN, Y.; MYNENI, R. B. Amazon forests did not green-up during the 2005 drought. **Geophysical Research Letters**, v. 37, n. 5, 2010.

SAMANTA, A.; KNYAZIKHIN, Y.; XU, L.; DICKINSON, R. E.; FU, R.; COSTA, M. H.; MYNENI, R. B. Seasonal changes in leaf area of Amazon forests from leaf flushing and abscission. **Journal of Geophysical Research: Biogeosciences**, v. 117, n. G1, 2012.

SANTOS, J. R.; GALVÃO, L. S.; ARAGÃO, L. E. O. C. Remote sensing of amazonian forests: Monitoring structure, phenology and responses to environmental changes. **Revista Brasileira de Cartografia**, v. 66, 2014.

SHIMABUKURO, Y. E.; NOVO, E. M.; PONZONI, F. J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do Pantanal. **Pesquisa Agropecuária Brasileira**, v. 33, n. 13, p. 1729-1737, 1998.

SILVA JUNIOR, C.H.L. **Global CHIRPS MCWD (Maximum Cumulative Water Deficit) Dataset**. Zenodo, 2021.

SILVA JUNIOR, C.H.L. Fire responses to the 2010 and 2015/2016 Amazonian droughts. **Frontiers in Earth Science**, v. 1, 2019.

SAUNDERS, R.W.; KRIEBEL, K.T. An improved method for detecting clear sky and cloudy radiances from AVHRR data. **International Journal of Remote Sensing**, v. 9, n. 1, p. 123-150, 1998.

SILVA, F. B.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. O. C.; ANDERSON, L. O.; PEREIRA, G.; CARDOZO, F.; ARAI, E. Corrigendum: Large-scale heterogeneity of Amazonian phenology revealed from 26-year long AVHRR/NDVI time-series. **Environmental Research Letters**, v. 8, e 024011, 2013.

SILVEIRA, M. V.; PETRI, C. A.; BROGGIO, I. S.; CHAGAS, G. O.; MACUL, M. S.; LEITE, C. C.; ARAGÃO, L. E. Drivers of fire anomalies in the Brazilian Amazon: lessons learned from the 2019 fire crisis. **Land**, v. 9, n. 12, p. 516, 2020.

SIMIONATO, J.; BERTANI, G.; OSAKO, L. S. Identification of artisanal mining sites in the Amazon rainforest using geographic object-based image analysis (GEOBIA) and data mining techniques. **Remote Sensing Applications: Society and Environment**, v. 24, e100633, 2021.

SIMÕES, P. S. **Estimativa de biomassa no Cerrado tocantinense utilizando a combinação de dados ópticos e de micro-ondas**. 2022. 70 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2022.

SIMS, D. A.; RAHMAN, A. F.; VERMOTE, E. F.; JIANG, Z. Seasonal and inter-annual variation in view angle effects on MODIS vegetation indices at three forest sites. **Remote Sensing of Environment**, 115, n. 12, p. 3112-3120, 2011.

SIMPSON, J. J.; GOBAT, J. I. Improved cloud detection for daytime AVHRR scenes over land. **Remote Sensing of Environment**, v. 55, p. 21-49, 1996.

SOUZA, C. M.; ROBERTS, D. Mapping forest degradation in the Amazon region with Ikonos images. **International Journal of Remote Sensing**, v. 26, n. 3, p. 425-429, 2005.

SOUZA JUNIOR, C.; FIRESTONE, L.; SILVA, L. M.; ROBERTS, D. Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. **Remote Sensing of Environment**, v. 87, n. 4, p. 494-506, 2003

SOUZA JUNIOR, C. M.; SIQUEIRA, J. V.; SALES, M. H.; FONSECA, A. V.; RIBEIRO, J. G.; NUMATA, I.; BARLOW, J. Ten-year Landsat classification of deforestation and forest degradation in the Brazilian Amazon. **Remote Sensing**, v. 5, n. 11, p. 5493-5513, 2013.

SOUZA, C.; BARRETO, P. An alternative approach for detecting and monitoring selectively logged forests in the Amazon. **International Journal of Remote Sensing**, v. 21, n. 1, p. 173-179, 2000.

SOUZA, C. M.; ROBERTS, D. A.; COCHRANE, M. A. Combining spectral and spatial information to map canopy damage from selective logging and forest fires. **Remote Sensing of Environment**, v. 98, n. 2/3, p. 329-343, 2005.

STOWE, L. L.; MCLAIN, E. P.; CAREY, R.; PELLEGRINO, P.; GUTMAN, G. G.; DAVIS, P.; LONG, C.; HART, S. Global distribution of cloud cover derived from NOAA/AVHRR operational satellite data. **Advances in Space Research**, v. 11, n. 3, p. 51-54, 1991.

VAN DER MEER, F. Analysis of spectral absorption features in hyperspectral imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 5, n. 1, p. 55-68, 2004.

WANG, J.; YANG, D.; DETTO, M.; NELSON, B. W.; CHEN, M.; GUAN, K.; WU, J. Multi-scale integration of satellite remote sensing improves characterization of dry-season green-up in an Amazon tropical evergreen forest. **Remote Sensing of Environment**, v. 246, e111865, 2020

WEIL, G.; LENSKY, I. M.; LEVIN, N. Using ground observations of a digital camera in the VIS-NIR range for quantifying the phenology of Mediterranean woody species. **International Journal of Applied Earth Observation and Geoinformation**, v. 62, p. 88–101, 2017.

WU, J.; ALBERT, L. P.; LOPES, A. P.; RESTREPO-COUBE, N.; HAYEK, M.; WIEDEMANN, K. T.; SALESKA, S. R. Leaf development and demography explain photosynthetic seasonality in Amazon evergreen forests. **Science**, v. 351, n. 6276, p. 972-976, 2016.

WU, S.; WANG, J.; YAN, Z.; SONG, G.; CHEN, Y.; MA, Q.; WU, J. Monitoring tree-crown scale autumn leaf phenology in a temperate forest with an integration of PlanetScope and drone remote sensing observations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 171, p. 36-48, 2021.

XIAO, W.; SUN, Z.; WANG, Q.; YANG, Y. Evaluating MODIS phenology product for rotating croplands through ground observations. **Journal of Applied Remote Sensing**, v. 7, n. 1, e 073562, 2013.

XIAO, X.; HAGEN, S.; ZHANG, Q.; KELLER, M.; MOORE III, B. Detecting leaf phenology of seasonally moist tropical forests in South America with multi-temporal MODIS images. **Remote Sensing of Environment**, v. 103, p. 465 – 473, 2006.

XU, L.; SAMANTA, A.; COSTA, M. H.; GANGULY, S.; NEMANI, R. R.; MYNENI, R. B. Widespread decline in greenness of Amazonian vegetation due to the 2010 drought. **Geophysical Research Letters**, v. 38, n. 7, 2011.

ZHOU, J.; YAN GUO, R.; SUN, M.; DI, T. T.; WANG, S.; ZHAI, J.; ZHAO, Z. The effects of GLCM parameters on LAI estimation using texture values from Quickbird satellite imagery. **Scientific Reports**, v. 7, n. 1, p. 1-12, 2017.

ZHU, Z.; WOODCOCK, C.E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v.118, p.83–94, 2012.