



PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E
GEODINÂMICA
INSTITUTO DE GEOCIÊNCIAS
UNIVERSIDADE DE BRASÍLIA

Dissertação de Mestrado nº 210
**COMPREENSÃO DA RESPOSTA DE ÍNDICES DE
VEGETAÇÃO SAR SOBRE O CERRADO BRASILEIRO**

Jales de Freitas Bussinguer

Orientador: Prof. Dr. Gustavo Macedo de Mello Baptista

Brasília, Fevereiro de 2023



PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E
GEODINÂMICA
INSTITUTO DE GEOCIÊNCIAS
UNIVERSIDADE DE BRASÍLIA

DISSERTAÇÃO DE MESTRADO
COMPREENSÃO DA RESPOSTA DE ÍNDICES DE VEGETAÇÃO SAR SOBRE O
CERRADO BRASILEIRO

Área de Concentração: Geoprocessamento e Análise Ambiental
Linha de Pesquisa: Avaliação de Dados e Técnicas de Sensoriamento Remoto,
Geoprocessamento, Cartografia e Geodésia
Aluno: Jales de Freitas Bussinguer
Orientador: Prof. Dr. Gustavo Macedo de Mello Baptista

Dissertação de Mestrado apresentada como
pré-requisito do Programa de Pós-Graduação
em Geociências Aplicadas e Geodinâmica, do
Instituto de Geociências da Universidade de
Brasília para a obtenção do título de Mestre
em Geociências Aplicadas.

Brasília - DF
Fevereiro de 2023

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

dB981c de Freitas Bussinguer, Jales
COMPREENSÃO DA RESPOSTA DE ÍNDICES DE VEGETAÇÃO SAR
SOBRE O CERRADO BRASILEIRO / Jales de Freitas Bussinguer;
orientador Gustavo Macedo de Mello Baptista. -- Brasília,
2023.
58 p.

Dissertação(Mestrado em Geociências Aplicadas) --
Universidade de Brasília, 2023.

1. SAR. 2. Cerrado. 3. Sentinel-1. 4. Índices de
Vegetação. I. Macedo de Mello Baptista, Gustavo, orient. II.
Título.

Esta obra é dedicada à minha mãe, Maria Elena de Freitas, que com seu exemplo de vida sempre me inspirou a alçar vôos mais altos.

AGRADECIMENTOS

Primeiramente, agradeço à minha companheira Vitória por todo amor, companheirismo, cuidado e por me alugar seu ouvido para as minhas palestrinhas. Obrigado por ser minha principal apoiadora e por ser quem você é. Quero viver com você até o fim dos meus dias. Te amo além do infinito!

À minha família nuclear, Maria Elena, Gilcelho e Fabrinio, pelo amor e por todo o apoio e incentivo para trilhar o caminho do conhecimento. Se eu cheguei até aqui, foi porque estive sobre os seus ombros.

Aos meus amigos, que complementam a minha existência e me presenteiam em compartilhar suas dores e alegrias comigo. Sou muito grato em dividir a vida com vocês, em especial Júlia e Pietro (e Lúcia), que sempre me recebem de braços abertos e compram minhas ideias malucas. Amo vocês!

Ao amigo Eduardo Mansur, que proveu a infraestrutura computacional necessária para a produção deste trabalho e para a jogatina. Obrigado por sua amizade e por me deixar fazer parte de um dos momentos importantes da sua vida. Te amo, meu amigo!

Ao meu orientador, Gustavo Baptista, que sempre acreditou no meu potencial e abriu o caminho para que eu realizasse essa pesquisa. Obrigado pela amizade construída desde os primeiros contatos (ainda na época do PDISL) e pelo acolhimento nos momentos difíceis.

Aos companheiros de GAtec, Fernando Bortolazzo e Andre Bindillati. Obrigado pelo apoio e por me darem a oportunidade de desenvolver minhas habilidades em projetos de alto nível. Sem suas contribuições, este trabalho não seria o mesmo.

Ao amigo Erlí Santos, pelas longas horas de discussão e debate de dúvidas sobre nossos trabalhos com SAR. Espero que nossa parceria renda muitos frutos de conhecimento.

A todos os colegas de pesquisa, em especial Gustavo Ferreira e Andrés Barrera. Agradeço pela camaradagem e pelas trocas de conhecimento. Juntos vamos além!

Meu agradecimento à todas as trabalhadoras e trabalhadores que construíram toda a infraestrutura necessária para a produção deste trabalho. Um agradecimento especial a Aida Kellen e Milene Busoli por cuidarem da minha saúde mental. Agradeço ainda aos trabalhadores do prédio em que resido, por proporcionarem as condições materiais para que eu pudesse me concentrar no trabalho intelectual.

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

"Se eu fosse uma onda de 5.6 cm, como seria minha interação com essa árvore?"

— Pensamento recorrente na mente do autor

Resumo

O bioma Cerrado tem sido pressionado pela expansão da fronteira agrícola nos últimos anos. As estratégias do governo brasileiro para monitorar o desmatamento no bioma utilizam principalmente imagens de satélite multiespectrais, cuja disponibilidade e qualidade são limitadas pela cobertura de nuvens nas cenas. A limitação dos dados ópticos em fornecer séries temporais densas ao longo dos anos cria a necessidade de alternativas para o monitoramento contínuo do Cerrado. Nesse contexto, diversos estudos investigaram o potencial dos dados de SAR para monitorar a vegetação do Cerrado devido à sua característica livre de nuvens, alta frequência de revisita e ampla cobertura espacial. Nos últimos anos, a crescente disponibilidade de dados abertos de SAR, liderada pela missão Sentinel-1, permitiu o desenvolvimento de vários índices de vegetação SAR como descritores de vegetação, a maioria focada no monitoramento de plantações. No entanto, até onde sabemos, estudos que investigam o uso de índices de vegetação SAR para mapear e monitorar o bioma Cerrado não foram abordados até o momento. Neste estudo, o comportamento temporal de cinco índices de vegetação SAR derivados de dados do Sentinel-1 foi investigado no período entre 2017 e 2021 para três classes de vegetação (Floresta, Savana e Campos de Cerrado) no Parque Nacional de Brasília. A análise dos perfis temporais demonstrou que todos os índices estudados seguem um padrão sazonal diretamente ligado ao regime pluviométrico no local de estudo. Dual-pol Radar Vegetation Index (DpRVI) e Radar Vegetation Index (RVI) foram relacionados à taxa de variação do sinal de radar sobre a vegetação em função da influência da sazonalidade. Por outro lado, Polarimetric Radar Vegetation Index (PRVI), Dual Pol SAR Vegetation Index (DPSVI) e Modified Dual Pol SAR Vegetation Index (DPSVIm) foram diretamente relacionados ao nível de biomassa das classes e suas variações ao longo do tempo. Verificou-se que a precipitação e as mudanças sazonais na estrutura da vegetação foram importantes impulsionadoras do deslocamento e da dispersão das distribuições espaciais dos índices ao longo do tempo. Nesse sentido, um fenômeno denominado equalização de índices foi observado em datas chuvosas, deslocando e espalhando as distribuições espaciais de todas as classes para as mesmas faixas de valor dos índices; degradando a separabilidade entre classes. Um teste de hipótese baseado na análise de distâncias estocásticas demonstrou que a similaridade entre as classes aumenta nas estações secas e diminui nas estações chuvosas. As curvas de rejeição da H₀ do DpRVI e RVI permaneceram acima de 97% sem um padrão sazonal claro. As curvas PRVI, DPSVI e DPSVIm para pares de classes apresentaram taxas de rejeição da H₀ acima de 94% dentro de um padrão sazonal.

Palavras-Chave: Cerrado, Séries Temporais, Distâncias Estocásticas

Abstract

The Cerrado biome has observed under pressure by the expansion of the agriculture frontier in the recent years. The Brazilian government methodological strategies for monitoring the deforestation in the biome encompasses the use of multispectral satellite imagery, whose availability and quality are constrained by the cloud cover in the scenes. The optical data limitation to provide dense time series all over the years raises the need of alternatives for the continuous monitoring of the preserved areas. In this context, various studies investigated the potential of SAR data to monitor the Cerrado vegetation due to its cloud-free characteristic, high revisit frequency and wide spatial coverage; which allows the continuous monitoring of the Brazilian savanna physiognomies. In the recent years, the increasing availability of open SAR data leaded by the Sentinel-1 mission allowed the development of various dual-pol SAR vegetation indices as descriptors of the vegetation, most of them focused on crop monitoring. However, to the best of our knowledge, studies that investigate the use of SAR vegetation indices to map and monitor the Cerrado biome have not been addressed until then. In this study, the temporal behavior of five SAR vegetation indices derived from Sentinel-1 data was investigated in the period between 2017 and 2021 for three vegetation classes (Forest, Savanna and Grasslands) in the Brasilia National Park, Brazil. Temporal profiles analysis showed that DpRVI, RVI, PRVI, DPSVI and DPSVIm follows a seasonal pattern directly linked with the rainfall regime in the study site. DpRVI and RVI were found related to the rate of radar signal variation over the vegetation as a function of the seasonality influence. PRVI, DPSVI and DPSVIm were found directly related with the biomass level of the classes and its variations over time. The precipitation and the seasonal vegetation structure changes were found as an important driver of the shift and the spread of the indices spatial distributions over time. In this regard, a phenomenon here called index equalization was observed on rainy dates, shifting and spreading all classes spatial distributions to the same indices values ranges; consequently degrading the separability between the classes. A hypothesis test based on stochastic distances analysis demonstrated that the similarity between the classes raises in the dry seasons and decreases in the wet seasons. The PRVI, DPSVI and DPSVIm curves for pairs of classes showed rates H₀ rejection above 94% within a seasonal pattern. The DpRVI and RVI H₀ rejection curves remained above 97% without a clear seasonal pattern.

Keywords: Cerrado, Time Series, Stochastic Distances

Lista de Figuras

1	Exemplo de distribuição dos pixels no gráfico de dispersão entre σ_{VV} e σ_{VH}	6
2	Região de estudo.	14
3	Rotina de preprocessamento automatizada dos produtos GRD e SLC.	15
4	Gráficos de dispersão H- α das classes nas estações úmida e seca. Os exemplos da estação úmida referem-se a 02/01/2019, e da estação seca referem-se a 19/06/2019. A divisão das zonas baseia-se na segmentação proposta por Ji e Wu (2015).	18
5	Perfis temporais de entropia e ângulo alfa (em graus) das classes de vegetação do PNB. As linhas representam a mediana espacial em cada data da série temporal. Os polígonos que envolvem as linhas de mediana indicam o intervalo interquartil (IQR) das distribuições espaciais de cada data. As barras azuis ao fundo representam a quantidade de precipitação medida no mesmo dia da aquisição da imagem, na estação pluviométrica da Represa Santa Maria.	20
6	Perfis temporais dos coeficientes de retroespalhamento σ_{VH} e σ_{VV} das classe em escala linear. As linhas representam a mediana espacial em cada data da série temporal. Os polígonos que envolvem as curvas de mediana representam o IQR das distribuições espaciais em cada data. As barras azuis indicam a quantidade de precipitação medida no mesmo dia da aquisição das imagens, na estação pluviométrica da Represa Santa Maria.	23

Sumário

1 INTRODUÇÃO	1
2 OBJETIVO	3
3 FUNDAMENTAÇÃO TEÓRICA	4
3.1 Índices SAR de vegetação baseados na polarização do coeficiente de retroespalhamento	4
3.1.1 <i>Radar Vegetation Index (RVI)</i>	4
3.1.2 <i>Dual Pol SAR Vegetation Index (DPSVI)</i>	6
3.1.3 <i>Modified Dual Pol SAR Vegetation Index (DPSVIm)</i>	8
3.2 Índices SAR de vegetação baseados no grau de polarização do sinal retroespalhado	9
3.2.1 <i>Polarimetric Radar Vegetation Index (PRVI)</i>	10
3.2.2 <i>Dual-Pol Radar Vegetation Index - (DpRVI)</i>	11
4 PARTE I - Análise de decomposição polarimétrica e coeficiente de retro-espalhamento (σ^0)	13
4.1 Área de estudo	13
4.2 Dados SAR e preprocessamento	13
4.3 Análise de decomposição polarimétrica dual-pol H- α	17
4.4 Análise dos coeficientes de retroespalhamento σ_{VH} e σ_{VV}	22
5 PARTE II - Análise dos índices SAR de vegetação	27
6 Conclusão	50
7 BIBLIOGRAFIA	54

1 INTRODUÇÃO

Ocupando aproximadamente 2 milhões de km² (aproximadamente 24% do território brasileiro), o Cerrado brasileiro é a savana mais diversa do mundo biologicamente (BUSTAMANTE et al., 2012). O Cerrado abriga mais de 12,000 espécies de plantas (JOLY et al., 2019) e um terço da biodiversidade brasileira, com alto grau de endemismo (KLINK; MACHADO, 2005). Considerado uma dos 34 *hotspots* de conservação da biodiversidade (MITTERMEIER et al., 2005), o bioma se encontra sob pressões de origem antrópica. Tais pressões se dão, principalmente, pelo fato de o Cerrado ocupar uma posição estratégica na economia brasileira devido à produção de *commodities* agrícolas (ALENCAR et al., 2020) e com a expansão da fronteira agrícola no país (SANO et al., 2019), especialmente na região do MATOPIBA (Maranhão, Tocantins, Piauí e Bahia) (SPERA et al., 2016). Esses quatro estados juntos foram responsáveis por 55% das perdas de vegetação nativa entre 2005 e 2017 (ALENCAR et al., 2020). Atualmente, estima-se que aproximadamente metade do domínio territorial do bioma tenha sido convertido em áreas agrícolas, pastagens ou algum outro tipo de ocupação humana (STRASSBURG et al., 2017; SANO et al., 2019; ALENCAR et al., 2020).

O mapeamento do Cerrado de 2021, produzido pelo projeto MapBiomass indica que aproximadamente 53% do território do Cerrado total foi classificado como vegetação natural. O mapa ainda aponta 46% do Cerrado mapeado como diferentes usos antrópicos, principalmente agricultura, aquicultura e mineração. Em termos de desmatamento, dados do projeto PRODES Cerrado no portal Terra Brasilis (ASSIS et al., 2016) demonstram uma tendência crescente de supressão da vegetação entre 2019 e 2022, período onde um total de 10.700 Km² de área desmatada foi detectada. Além disso, em 2022, o Sistema de Alerta de Desmatamento do Cerrado (SAD-Cerrado) reportou 91.768 alertas de desmatamento englobando uma área de 8.155,32 Km², principalmente na região do MATOPIBA (ALENCAR et al., 2022).

Tais estratégias de monitoramento do Cerrado se baseiam principalmente na utilização de dados de sensores multiespectrais. Contudo, o monitoramento do bioma por imagens multiespectrais e seus derivados é dificultado devido às extensas e persistentes coberturas de nuvens em algumas áreas e à alta sazonalidade climática (SILVA; SANO, 2016). Além disso, a vegetação do Cerrado é caracterizada como um mosaico de diferentes proporções de florestas ripárias, florestas decíduas e semi-decíduas, florestas de savana, matagais e campos, com fenologias de dinâmica altamente sazonal (SANO et al., 2021).

Para contornar essas limitações dos dados multiespectrais, pesquisas foram conduzidas com dados de radares de abertura sintética (SAR). A principal vantagem de

utilização desses dados é o fato de que a radiação de microondas é capaz de atravessar nuvens, garantindo um imageamento contínuo em diferentes condições meteorológicas e de iluminação. Historicamente, as pesquisas de mapeamento do Cerrado a partir de dados SAR estiveram concentradas na utilização dos coeficientes de retroespalhamento (σ^0 , β^0 e γ^0) e variáveis polarimétricas como entropia (H) e ângulo alfa (α). Alguns exemplos são Sano et al. (2001), Sano et al. (2005), Mendes et al. (2019), Bispo et al. (2020) Zimbres et al. (2021) e Lewis et al. (2021).

Nos últimos 6 anos, a crescente disponibilidade de dados SAR liderada pela Agência Espacial Europeia (ESA) com a missão Sentinel-1 impulsionou o desenvolvimento de índices SAR de vegetação como DPSVI (PERIASAMY, 2018), PRVI (CHANG et al., 2018), RVI (NASIRZADEHDIJAZI et al., 2019), DpRVI (MANDAL et al., 2020) e DPSVIm (SANTOS et al., 2021), em sua maioria destinados ao monitoramento de culturas agrícolas. Os índices SAR de vegetação são modelos matemáticos que se aproveitam das propriedades polarimétricas da interação do sinal de radar com a cobertura vegetal para melhorar o contraste entre vegetação e outros alvos terrestres, simplificando a análise dos dados SAR. Contudo, até o momento, não foram identificados estudos que abordam a utilização de índices SAR de vegetação para o monitoramento do Cerrado.

2 OBJETIVO

A partir desse contexto, este estudo levanta a seguinte pergunta científica: Como os índices de vegetação derivados de dados SAR de dupla polarização descrevem a vegetação do Cerrado ao longo do tempo? A pergunta está baseada na premissa de que, conhecendo e compreendendo a dinâmica sazonal de uma área de Cerrado preservado por meio de dados SAR é possível identificar e interpretar melhor eventuais perturbações no futuro. Portanto, o principal propósito deste trabalho é investigar o potencial dos índices de vegetação derivados dos dados SAR da constelação Sentinel-1 como indicadores das dinâmicas sazonais da vegetação do Cerrado.

Para responder a essa pergunta, a primeira parte desse trabalho explora o comportamento espaço-temporal do coeficiente de retroespalhamento σ^0 e das variáveis polarimétricas entropia (H) e ângulo alfa (α) de três fitofisionomias do Cerrado no Parque Nacional de Brasília (PNB): Formação Florestal, Formação Savânica e Formação Campestre. O objetivo foi caracterizar distribuições espaciais e tendências temporais dessas variáveis, configurando um conhecimento-base para a interpretação dos índices SAR de vegetação.

A segunda parte é um artigo que trata do comportamento espaço-temporal de cinco índices SAR de vegetação para as três classes que representam as fitofisionomias do Cerrado contidas no PNB. O nível de separabilidade entre as classes estudadas também foi analisado, com o propósito de compreender como a sazonalidade climática influencia as distribuições espaciais dos índices SAR de vegetação no domínio temporal.

3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será apresentado um panorama dos índices de vegetação ópticos e SAR, além de explorar o estado da arte no uso conjunto destes índices. As seções estão organizadas da seguinte maneira: primeiramente serão abordados os índices SAR de vegetação e suas especificidades. Os índices estudados estão organizados em duas categorias: 1) índices baseados no coeficiente de retroespalhamento e 2) índices baseados no grau de polarização do sinal.

3.1 Índices SAR de vegetação baseados na polarização do coeficiente de retroespalhamento

Os índices apresentados a seguir são baseados na polarização do coeficiente de retroespalhamento. Estes estabelecem relações entre o sinal co-polarizado (VV ou HH) e o sinal de polarização cruzada (VH ou HV) para prover informações sobre a vegetação. Suas formulações são análogas às formulações dos índices ópticos, constituindo-se de operações aritméticas entre bandas radiometricamente calibradas de imagens SAR.

3.1.1 *Radar Vegetation Index (RVI)*

O índice RVI foi proposto por Kim e Van Zyl (2009) como um parâmetro sensível ao nível de biomassa da vegetação utilizando dados das quatro polarizações (HH, HV, VV e VH) na banda L. O índice baseia-se na modelagem da estrutura da vegetação por uma coleção de dipolos com orientação aleatória e pode ser interpretado como uma medida da aleatoriedade do sinal provocada pelo retroespalhamento volumétrico dos alvos de vegetação (ARII et al., 2010; KIM et al., 2012; SZIGARSKI et al., 2018; MANDAL et al., 2020). Kim et al. (2012) constatou que o RVI apresenta boas correlações com parâmetros biofísicos como conteúdo hídrico da vegetação (*Vegetation Water Content - VWC*) e índice de área foliar (*Leaf Area Index - LAI*) e com o índice NDVI.

Sua formulação é dada pela Equação 1. O índice varia entre 0 e 1, onde valores próximos a zero representam superfícies lisas e valores próximos a 1 representam regiões de vegetação densa (KIM et al., 2012).

$$RVI = \frac{8 \times \sigma_{hv}^0}{\sigma_{hh}^0 + \sigma_{vv}^0 + 2 \times \sigma_{hv}^0} \quad (1)$$

Szigarski et al. (2018) apontam que, em alguns casos, o RVI pode superestimar ou subestimar o retroespalhamento volumétrico da vegetação por se tratar de um índice derivado em uma razão aritmética. Além disso, os autores constatam que os valores derivados da formulação original do RVI podem ultrapassar o valor de 1 devido à falta de calibração do fator multiplicativo 8 no numerador do índice.

Apesar dos avanços no aprimoramento do RVI, sua utilização se restringe a dados com as quatro polarizações, geralmente obtidos na banda L. Dentro desse contexto, diferentes autores trabalharam na simplificação do RVI para sua implementação em dados de polarização dupla, principalmente da constelação Sentinel-1.

Trudel et al. (2012) propõem uma implementação do RVI para dados com duas polarizações. Tal proposição parte da suposição que $\sigma_{hh} \approx \sigma_{vv}$, levantada por Charbonneau et al. (2005). Dessa forma, o RVI passa a ter a seguinte formulação (Eq. 2). O estudo feito por Trudel et al. (2012), utilizando dados do satélite RADARSAT-2 (HH e HV) concluiu que essa simplificação é uma alternativa plausível quando apenas duas polarizações estão disponíveis, podendo ser considerada uma boa aproximação do retroespalhamento de superfície quando a interação entre o solo e a vegetação é desprezível.

$$RVI_{dual-pol} = \frac{4 \times \sigma_{hv}^0}{\sigma_{hh}^0 + \sigma_{hv}^0} \quad (2)$$

Partindo do mesmo princípio, Nasirzadehdizaji et al. (2019) propõem uma versão alternativa do dual-pol RVI, adaptando a formulação para sua implementação a partir dos dados do Sentinel-1 (VV e VH). Tal proposição é comumente referida como S1-RVI (Eq. 3). O estudo reporta correlações positivas entre o S1-RVI e alturas de plantas menores que 1.5 m ($R^2 = 0.53$) e cobertura do dossel maior que 75% ($R^2 = 0.29$), evidenciando seu potencial para a estimativa da altura e do nível de cobertura das plantas.

$$RVI_{dual-pol} = \frac{4 \times \sigma_{vh}^0}{\sigma_{vv}^0 + \sigma_{vh}^0} \quad (3)$$

3.1.2 Dual Pol SAR Vegetation Index (DPSVI)

O DPSVI é um modelo matemático proposto por (PERIASAMY, 2018) com o objetivo de preencher uma lacuna de representação da vegetação terrestre por meio de índices de vegetação desenvolvidos a partir de dados da constelação Sentinel-1. O índice é fundamentado na distribuição dos pixels de água, solo e vegetação no gráfico de dispersão dos coeficientes de retroespalhamento nas polaridades VV e VH (Figura 1).

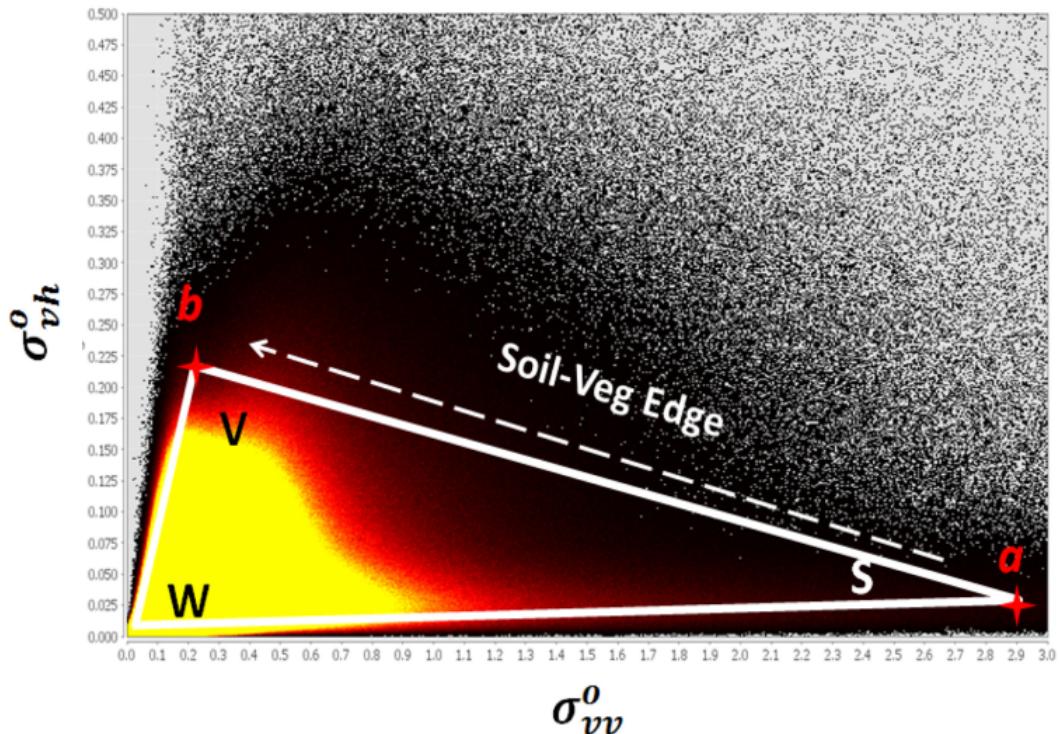


Figura 1: Exemplo de distribuição dos pixels no gráfico de dispersão entre σ_{VV} e σ_{VH} .
Fonte: (PERIASAMY, 2018)

O padrão de distribuição dos alvos no gráfico de dispersão, aproximado por um triângulo, ocorre segundo o grau de polarização (DOP) do sinal retroespelhado pelos alvos terrestres. Na interação entre o sinal transmitido pelo sistema sensor e o interior da vegetação, há a predominância de retroespalhamento volumétrico. O alto grau de aleatoriedade dessa interação leva a um maior grau de depolarização do sinal e, consequentemente, a um maior retroespalhamento na polaridade VH. Dessa forma, os pixels da vegetação ocupam a parte superior do triângulo aproximado. Os corpos d'água, por serem superfícies suaves ou ligeiramente rugosas, estão restritos a baixos valores de coeficiente de retroespalhamento em ambas polarizações devido à predominância de retroespalhamento especular. Sendo assim, os pixels dos corpos d'água

ocupam a porção localizada no canto inferior esquerdo do triângulo aproximado.

Segundo Periasamy (2018), as regiões de solo exposto tendem a não causar mudanças significativas na polarização do sinal transmitido. Dessa forma, grande parte do sinal retorna ao sensor na polaridade VV, devido à predominância de retroespalhamento espelhado nessas regiões. Com isso, os pixels de solo localizam-se na porção inferior à direita do triângulo aproximado.

Um importante conceito introduzido pela autora é o limiar solo-vegetação (Figura 1) que tem origem no ponto de máximo valor de retroespalhamento de σ_{vv} . O valor do limiar aumenta gradualmente de acordo com o aumento da distância diagonal entre os coeficientes de retroespalhamento, até chegar ao máximo valor de σ_{vh} . Dessa forma, o limiar solo-vegetação representa o solo na faixa inferior e a vegetação na faixa superior.

A formulação do DPSVI (Eq. 4) é uma função dos parâmetros IDPDD, VDDPI e do coeficiente de retroespalhamento na polarização VH. Os valores do índice são matematicamente normalizados e o valor resultante aumenta com o aumento da biomassa.

$$DPSVI = f(IDPDD, VDDPI, \sigma_{vh})$$

$$DPSVI = \frac{\sigma_{vh}^0 ((\sigma_{vvmax}^0 \times \sigma_{vh}^0 - \sigma_{vv}^0 \times \sigma_{vh}^0 + \sigma_{vh}^{0,2}) + (\sigma_{vvmax}^0 \times \sigma_{vv}^0 + \sigma_{vh}^0 \times \sigma_{vv}^0 - \sigma_{vv}^{0,2}))}{\sqrt{2} \times \sigma_{vv}^0} \quad (4)$$

onde

σ_{vvmax}^0 : máximo valor observado na polarização VV;

σ_{vv}^0 : valor do pixel na polarização VV;

σ_{vh}^0 : valor do pixel na polarização VH.

Na equação, o primeiro parâmetro é o chamado *Inverse dual-pol diagonal distance* (IDPDD), que diferencia os alvos a partir da distância diagonal inversa do limiar solo-vegetação. Com isso, pequenas distâncias diagonais representam o solo e, à medida que a distância aumenta, passa a indicar presença de vegetação.

O segundo parâmetro é o chamado *Vertical dual de-polarization index* (VDDPI) que distingue os alvos a partir da razão entre a quantidade total de sinal transmitido e a porção do sinal que retorna ao sensor na mesma polarização. Isto é equivalente à uma estimativa do grau o qual a superfície depolariza o sinal transmitido. Dessa forma, os alvos que não provocam a mudança da polarização do sinal apresentam valores pequenos, enquanto que os valores que depolarizam o sinal apresentam valores maiores.

O terceiro parâmetro é o coeficiente de retroespalhamento na polaridade VH. Este é adicionado ao modelo com o objetivo de garantir o posicionamento adequado dos alvos nas faixas de valores, assim como os índices ópticos e outros índices SAR.

Segundo Periasamy (2018), os valores mais extremos do índice demonstram potencial para a identificação de florestas. Contudo, de acordo com Nizalapur e Madugundu (2010), a capacidade de penetração da banda C na vegetação é de aproximadamente 1 metro, com saturação do sinal em regiões de biomassa em torno de 60 a 70 ton./ha. Dessa forma, o valor dos pixels dessas regiões pode não representar a totalidade da biomassa presente no território.

O índice foi testado em regiões de culturas agrícolas com vegetações densas e esparsas, apresentando fortes correlações com o NDVI ($R^2=0.749$ para a estação seca e $R^2=0.726$ para a estação chuvosa). Em relação aos dados alométricos de biomassa, o índice apresentou altos níveis de acurácia ($R^2=0.73$ na estação seca e $R^2=0.70$ na estação chuvosa). Tais resultados indicam que o DPSVI é capaz de apresentar os mesmos níveis de acurácia que índices ópticos e SAR previamente desenvolvidos apenas com duas polarizações (PERIASAMY, 2018). Por fim, a autora faz importantes recomendações quanto à aplicação do DPSVI. A primeira recomendação é a de que o índice deve ser aplicado apenas em imagens SAR com polarização vertical (VV-VH) radiometricamente calibradas em escala linear. Além disso, o índice não é indicado para regiões com terreno extremamente ondulado, uma vez que a rugosidade do solo pode afetar a diferenciação entre solo e vegetação em função dos mecanismos de retroespalhamento.

3.1.3 Modified Dual Pol SAR Vegetation Index (DPSVIm)

O índice DPSVIm foi proposto por Santos et al. (2021) como uma adaptação do DPSVI. As modificações propostas pelos autores objetivam representar vegetações densas a partir de dados da banda C da constelação Sentinel-1. A primeira alteração proposta é a substituição do parâmetro IDPDD pelo parâmetro DPDD (*Dual Polarization Diagonal Distance*) (Eq. 5). Tal proposição baseia-se nas considerações de Periasamy (2018), que apontam que o IDPDD tende a saturar em regiões de biomassa densa, indicando o DPDD como um índice mais sensível à vegetação densa.

$$DPDD = \frac{\sigma_{vv}^0 + \sigma_{vh}^0}{\sqrt{2}} \quad (5)$$

A segunda alteração proposta é a substituição do parâmetro VDDPI (*Vertical dual de-polarization index*) pelo parâmetro CR (*Cross Ratio*) (Eq. 6). Segundo Santos et

al. (2021), o CR possui melhor capacidade de distinguir os pixels de vegetação por apresentar um comportamento exponencial em relação ao VDDPI.

$$CR = \frac{\sigma_{vv}^0}{\sigma_{vh}^0} \quad (6)$$

A formulação final do DPSVIm (Eq. 7) inclui o σ_{vh}^0 como fator de distinção entre os pixels de solo e corpos d'água. O resultado é um índice matematicamente normalizado.

$$DPSVIm = \frac{\sigma_{vv}^0 + \sigma_{vh}^0}{\sqrt{2}} \times \frac{\sigma_{vv}^0}{\sigma_{vh}^0} \times \sigma_{vh}^0 \quad (7)$$

A fim de analisar a sensibilidade do DPSVIm em representar vegetações densas, comparou-se os resultados do índice com o NDVI e o EVI calculados a partir dos dados do sensor Landsat 8. O mesmo procedimento foi realizado com o DPSVI. Dessa análise constatou-se que o DPSVIm apresenta correlações superiores com o NDVI e o EVI em relação ao DPSVI em fragmentos de Mata Atlântica. Além disso, o DPSVIm apresentou correlação e concordância em relação aos dados alométricos de biomassa, modelados a partir de medições em áreas aproximadamente planas, sendo capaz de distinguir pixels com biomassa de aproximadamente 50.0 Mg/ha.

Santos et al. (2021) apontam que os maiores valores de correlação positiva ocorreram nas estações secas dos anos hidrológicos analisados, comportamento verificado em todas as regiões estudadas. Tal resultado é esperado, haja vista a sensibilidade dos sensores SAR à umidade da superfície dos alvos. Os autores ainda apontam que a influência das chuvas ao longo do ano hidrológico insere incertezas na performance do DPSVIm, resultando em menores correlações na estação chuvosa. Outro ponto discutido é a variação de performance do índice relacionada à escala de análise. Os autores estabelecem que a correlação entre o DPSVIm e os índices ópticos aumenta de acordo com o aumento da escala, isto é, diminuição na área analisada.

3.2 Índices SAR de vegetação baseados no grau de polarização do sinal retroespalhado

Os índices apresentados a seguir baseiam-se no grau de polarização (DOP) do sinal retroespalhado, expresso pela razão entre a energia polarizada e a energia total transmitida pelo sensor. O DOP pode medir o retroespalhamento volumétrico da vegetação com menor influência topográfica do que os coeficientes de retroespalhamento com polarização cruzada (CLOUDE; POTTIER, 1997).

3.2.1 Polarimetric Radar Vegetation Index (PRVI)

O índice PRVI foi proposto por Chang et al. (2018) com o objetivo de se obter um indicador de biomassa de vegetações arbustivas por meio de dados SAR. Conceitualmente, a formulação do PRVI (Eq. 8) baseia-se no grau de polarização (DOP) de ondas parcialmente polarizadas e no coeficiente de retroespalhamento de polarização cruzada (CHANG et al., 2018).

$$PRVI = (1 - DOP) \times \sigma_{xy}^0 \quad (8)$$

onde

$1 - DOP$: porção não-polarizada do sinal transmitido, considerada uma representação da componente de retroespalhamento volumétrico dos alvos (RANEY et al., 2012).

σ_{xy}^0 : coeficiente de retroespalhamento de polarização cruzada.

A combinação entre DOP e σ_{xy}^0 é baseada nos seguintes fatores (CHANG et al., 2018): 1) a diferença de sensibilidade à biomassa entre DOP e σ_{xy}^0 , evidenciada por (CHANG; SHOSHANY, 2017); 2) a utilização do σ_{xy}^0 para a redução na ambiguidade do retroespalhamento entre solo exposto e vegetações arbustivas esparsas; 3) a moderação do efeito de retroespalhamento direto de σ_{xy}^0 para densidades de vegetação arbustiva médias e altas pelo uso do DOP . Dentro deste contexto, Yadav et al. (2021) advertem que o termo de polarização cruzada pode ser responsável por evidenciar uma saturação do coeficiente de retroespalhamento e falsamente apresentar altos níveis de retroespalhamento mesmo quando a vegetação não está desenvolvida.

Chang et al. (2018) conduziram uma análise empírica de correlações entre a biomassa modelada a partir do NDVI (Landsat TM) e os dados dos sensores ALOS-PALSAR 2 (banda L) e Sentinel-1 (banda C). Os resultados das análises de regressões lineares simples e múltiplas mostram que os dados do Sentinel-1 apresentam baixa correlação com a biomassa de vegetações arbustivas modeladas a partir do NDVI, supostamente em razão de uma penetração mais rasa na vegetação arbustiva comparada aos dados da banda L.

No estudo original, os autores implementam o PRVI utilizando o DOP calculado a partir da Matriz Modificada de Mueller com parâmetros de Stokes, utilizando dados com as quatro polarizações (HH, HV, VV, VH) do sensor ALOS/PALSAR-2. A polarização HV foi utilizada como parâmetro de retroespalhamento de polarização cruzada. Os resultados indicam que o PRVI apresenta baixa variação em função do ângulo de incidência em comparação com o RVI, sendo um modelo mais adequado para estudos de vegetações arbustivas em regiões com alta heterogeneidade topográfica. Da aná-

lise de correlação do PRVI com a biomassa modelada a partir do NDVI, os resultados sugerem que há boa concordância em regiões de densidade de vegetação arbustiva moderadas e altas, enquanto que há uma superestimativa em regiões de vegetação esparsa. Contudo, os autores advertem que o PRVI pode ser usado apenas como uma estimativa generalizada de biomassa para amplas zonas de transição entre ambientes áridos e semi-áridos, carecendo de testes que abordem a variabilidade sazonal.

Considerando o modelo conceitual do PRVI, é possível implementá-lo com os dados do Sentinel-1. Mandal et al. (2020) mostram que cálculo do *DOP* pode ser realizado utilizando-se a formulação de Barakat (1977) (Eq. 9) para dados de polarização dupla (HH-HV ou VV-VH).

$$DOP_{dp} = \sqrt{1 - \frac{4 \times \det([C_2])}{(\text{Trace}[C_2])^2}} \quad (9)$$

onde

C_2 : Matriz de covariância 2x2.

Com isso, a formulação do PRVI para os dados do Sentinel-1 passa a ser dada pela Equação 10. É importante destacar que a implementação do DpPRVI apenas adapta a forma como os parâmetros do índice são calculados de modo a permitir o uso de dados de polarização dual.

$$PRVI_{Sentinel-1} = (1 - DOP_{dp}) \times \sigma_{vh}^0 \quad (10)$$

3.2.2 Dual-Pol Radar Vegetation Index - (DpRVI)

O índice foi proposto por Mandal et al. (2020) para o monitoramento de culturas agrícolas a partir dos dados da constelação Sentinel-1. Este utiliza o grau de polarização do sinal (*DOP*) e informações do espectro de autovalores (λ) derivadas da matriz de covariância C_2 para medir a aleatoriedade do sinal retroespelhado. Para os dados de polarização dupla o *DOP* é equivalente à anisotropia, métrica que quantifica a força relativa entre o primeiro e o segundo mecanismo de retroespelhamento dominantes (MANDAL et al., 2020). A ordem de retroespelhamento aumenta com o avanço dos estágios fenológicos das plantas, com consequente decrescimento do *DOP* em função do aumento do retroespelhamento volumétrico (MANDAL et al., 2020).

A principal característica do DpRVI é a abordagem da dominância de mecanismo de retroespelhamento. A informação é derivada dos dois autovalores positivos ($\lambda_1 \geq \lambda_2 \geq 0$) obtidos da decomposição própria da matriz de covariância C_2 normalizados pela amplitude do sinal transmitido ($\lambda_1 + \lambda_2$). Para o caso de apenas um mecanismo de

retroespalhamento dominante no pixel $\lambda_1 \gg \lambda_2$ (MANDAL et al., 2020). Partindo desse princípio, os autores propõem a utilização do parâmetro β (Eq. 11) como medida de dominância do mecanismo de retroespalhamento. Em termos gerais, o parâmetro β indica a contribuição do mecanismo de retroespalhamento dominante no total do sinal retroespalhado.

$$\beta = \frac{\lambda_1}{\lambda_1 + \lambda_2} \quad (11)$$

A formulação do DpRVI (Eq. 12) é similar à do PRVI. Contudo, no DpRVI o *DOP* é modulado por meio de um produto com a informação do mecanismo de retroespalhamento dominante, ao passo que no PRVI é utilizado o coeficiente de retroespalhamento na polarização cruzada para esse fim. A aleatoriedade do retroespalhamento é então obtida pela subtração do produto $DOP \times \beta$ de um fator unitário. Segundo Mandal et al. (2020), o principal motivo de combinar o *DOP* com β é a diferença de sensibilidade desses parâmetros à dinâmica de crescimento de culturas agrícolas onde, apesar de apresentarem tendências análogas, estes variam em faixas de valores distintas em diferentes estágios fenológicos. Em resumo, o DpRVI pode ser considerado uma medida da aleatoriedade do retroespalhamento em que, quanto maior é a aleatoriedade, maior a influência do retroespalhamento volumétrico e maior é a influência da vegetação no pixel.

$$DpRVI = 1 - (DOP \times \beta), \quad 0 \leq DpRVI \leq 1 \quad (12)$$

4 PARTE I - Análise de decomposição polarimétrica e coeficiente de retroespalhamento (σ^0)

Nesta seção serão apresentadas as análises e interpretações de dados derivados de decomposição polarimétrica dual-pol H-alpha e coeficiente de retroespalhamento (σ^0). Primeiramente, foi realizada análise temporal dos parâmetros polarimétricos entropia e ângulo alfa. A análise desses parâmetros polarimétricos teve como objetivo retratar como os mecanismos de espalhamento e a aleatoriedade do sinal de radar foram afetados pelo regime de sazonalidade no Parque Nacional de Brasília. A análise polarimétrica compreende a plotagem e interpretação do gráfico de dispersão H-alfa e dos perfis temporais da mediana espacial e valores de IQR. A análise de retroespalhamento foi realizada para saber como a resposta de intensidade SAR-C às classes vegetações foi afetada pelo regime de chuvas no PNB. A análise combinada dos parâmetros polarimétricos e de intensidade foi feita para embasar o entendimento dos resultados da análise dos índices de vegetação SAR.

4.1 Área de estudo

A área de estudo compreende o Parque Nacional de Brasília (PNB), localizado no Distrito Federal (Figura 2). Com área aproximada de 30.000 ha, o parque é considerado um importante sítio de pesquisa e conservação, pois abrange as principais fitofisionomias encontradas no cerrado (SANO et al., 2005). De acordo com o mapa da cobertura do Cerrado de 2020, produzido pelo MapBiomas em escala 1:100.000, as fitofisionomias presentes área de estudo são Formação Florestal, Formação Savânica e Formação Campestre.

A classe *Forest* (FT) diz respeito à vegetação de matas de galeria, com predominância de espécies arbóreas que formam um dossel contínuo ao redor dos cursos d'água do PNB. A classe *Savanna* (SV) é constituída por árvores dispersas e arbustos, formando um dossel descontínuo sobre um estrato herbáceo. Já a classe *Grassland* (GL) é dominada pelo estrato herbáceo com presença em baixas proporções de arbustos e subarbustos.

4.2 Dados SAR e preprocessamento

Para a composição da série temporal de dados SAR, foram utilizados os produtos Level-1 GRD (*Ground Range Detection*) e Level-1 SLC (*Single Look Complex*) da constelação Sentinel-1 (ESA). Os satélites dessa constelação operam na banda C,

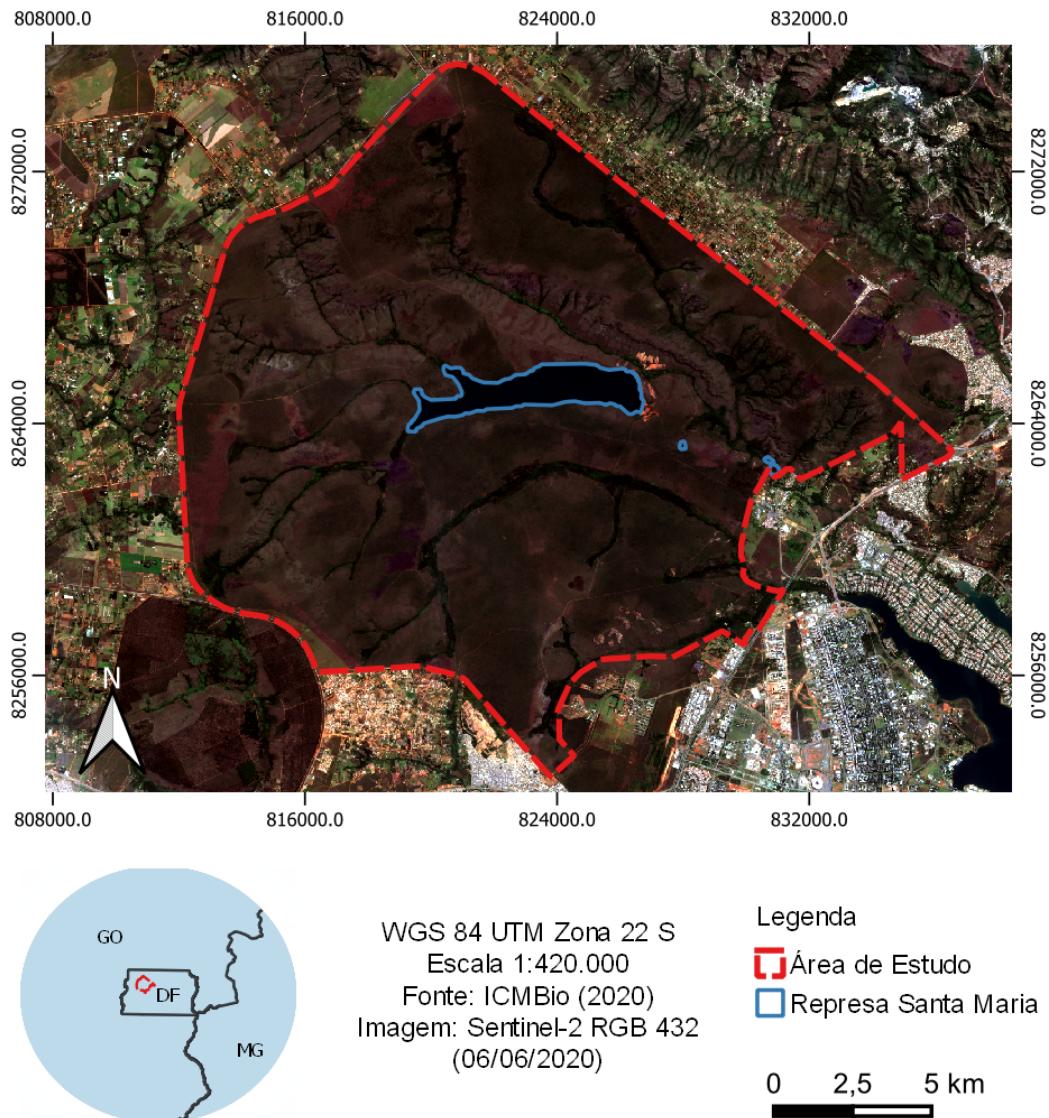


Figura 2: Região de estudo.

com frequência central de 5.4 GHz ($\lambda \approx 5.54\text{cm}$), adquirindo imagens nas polaridades VV e VH sob o modo IW (*Interferometric Wide Swath*). A aquisição das imagens utilizadas neste trabalho foi feita em órbitas descendentes em faixas de 250 km com resolução espacial de 5 m (direção transversal) x 20 m (direção azimutal) e ângulos de incidência que variam entre 29.1° e 46.0°. Os dados foram adquiridos gratuitamente pelo portal da *Alaska Satellite Facility*, cobrindo o período de janeiro de 2017 a dezembro de 2021.

Os produtos SLC e GRD foram submetidos a rotinas de preprocessamento automatizadas (Figura 3), de modo a preparar os dados para o processamento dos índices SAR de vegetação e para análises preliminares de entropia, ângulo alfa e coeficiente de retroespalhamento. Todos os procedimentos foram executados em lote, por meio

de *scripts* em linguagem Python utilizando a biblioteca *snappy*.

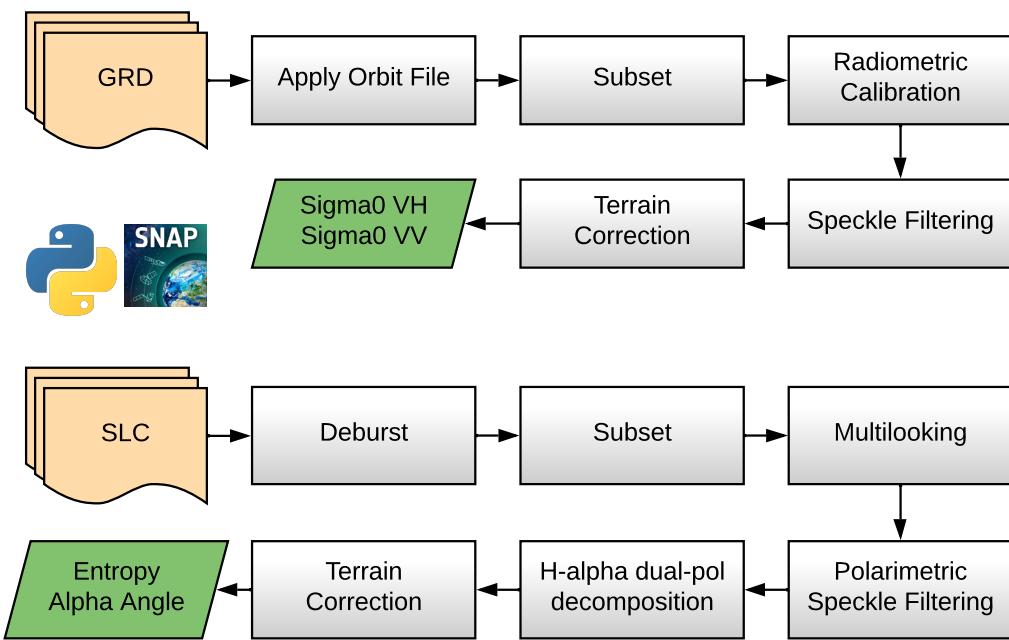


Figura 3: Rotina de preprocessamento automatizada dos produtos GRD e SLC.

As principais metodologias de decomposição polarimétrica são Van Zyl (ZYL, 1989), Yamaguchi (YAMAGUCHI et al., 2005), Freeman-Durden (FREEMAN; DURDEN, 1998) e Claude-Pottier (CLOUDE; POTTIER, 1997). Contudo, tais métodos necessitam de dados com as quatro polarizações, não sendo possível sua implementação para dados dual-pol do Sentinel-1. O software SNAP fornece a opção de processar a decomposição polarimétrica H-alpha (CLOUDE; POTTIER, 1997) para dados de dupla polarização, sendo esta utilizada neste estudo para derivar as informações de entropia e ângulo alfa.

Para o processamento da decomposição polarimétrica H-alpha, o primeiro passo foi a seleção dos *swaths* e *bursts* que interceptam a região de estudo com a biblioteca Python STSA e o operador *TOPS Split*. Os arquivos vetoriais de órbita foram atualizados e em seguida as imagens passaram pelo processamento de *deburst*, *multilook* com 4x1 nas direções *range* e *azimuth* e então recordadas para a extensão do PNB. A filtragem de ruído *speckle* foi executada por meio do filtro polarimétrico Refined Lee com uma janela de convolução de 3x3. Sequentemente, o processamento da decomposição polarimétrica H-alpha foi executada e o georreferenciamento dos resultados foi corrigido com o operador *Range Doppler Terrain Correction*. O produto final de cada imagem foi um arquivo Geotiff contendo as informações de entropia, anisotropia e ângulo alfa, com pixels re amostrados de 10m.

Para o processamento dos coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 , o primeiro passo foi atualizar os arquivos vetoriais de órbita dos produtos GRD. Em seguida, as imagens foram recortadas para a extensão territorial do PNB. A calibração radiométrica foi então processada para os dados de amplitude das polarizações VV e VH. Em sequência, a filtragem de ruído *speckle* foi executada utilizando o filtro *Refined Lee* com uma janela de convolução de 3x3. Por fim, o georreferenciamento das imagens foi corrigido pelo operador *Range Doppler Terrain Correction*. O produto final de cada imagem foi um arquivo Geotiff contendo σ_{VV}^0 e σ_{VH}^0 , com pixels de 10m expressos em escala linear.

4.3 Análise de decomposição polarimétrica dual-pol H- α

Os gráficos de dispersão para as estações úmida e seca (Figure 4) sugerem que as três classes de vegetação apresentam aproximadamente os mesmos níveis em termos de entropia e ângulo alfa. Todas as classes ocupam diferentes zonas do gráfico que cobrem regiões de baixa, média e alta entropia, enquanto suas regiões mais densas ocupam a mesma Zona 4 em ambas estações. As mudanças no retroespalhamento a partir da estação seca para a úmida foram observadas principalmente com deslocamentos das regiões mais densas das classes para regiões de entropia e ângulo alfa ligeiramente maiores. A amplitude dos deslocamentos foi maior na classe *Grassland*, seguida de *Savanna* e *Forest*, respectivamente.

Os deslocamentos observados entre as estações são provavelmente conduzidos pelas mudanças estruturais nas vegetações das classes, em função dos efeitos da sazonalidade das chuvas e da interferência da precipitação no sinal retroespalhado. A vegetação da classe *Forest* não muda significativamente ao longo das estações devido à sua condição perene, refletindo em deslocamentos menores observados nos gráficos de dispersão. O mesmo ocorreu na classe *Savanna* em função da presença de agrupamentos de árvores em seu domínio territorial. Contudo, a presença de arbustos e gramíneas dentro da classe provavelmente balanceia a resposta média da classe. Em contraste, a vegetação da classe *Grassland* apresentou os maiores deslocamentos de sua região mais densa no gráfico de dispersão. Tal nível de deslocamento se deu provavelmente pela alta influência da sazonalidade de chuvas na vegetação gramínea e pela influência da umidade do solo no sinal retroespalhado nessas regiões.

Os deslocamentos observados em todas as classes não foram suficientes para mudar o modo em que a vegetação retroespalha o sinal da banda C, isto é, mudar as zonas ocupadas no gráfico de dispersão. Neste estudo, todas 149 cenas foram adquiridas sob a mesma órbita descendente, com um ângulo de incidência médio de 38.14°. Resultados reportados por Weiß et al. (2021) sugerem que, em uma série temporal, as variações nos mecanismos de retroespalhamento de dados SAR de dupla polarização são principalmente conduzidas pelo ângulo de incidência. Em um ângulo de incidência médio de 35° em órbita descendente, variações mais pronunciadas de entropia e ângulo alfa foram observadas entre diferentes zonas do gráfico de dispersão do que para um ângulo de incidência médio de 43°. Tais resultados referem-se a diferentes estágios fenológicos de plantações de trigo de inverno na Bavária, Sul da Alemanha.

É importante destacar que a comparação direta entre culturas de trigo e fitofisionomias de Cerrado é dificultada devido às diferenças nos ciclos fenológicos de ambas vegetações. Os estágios fenológicos das culturas de trigo de inverno se desenvolvem

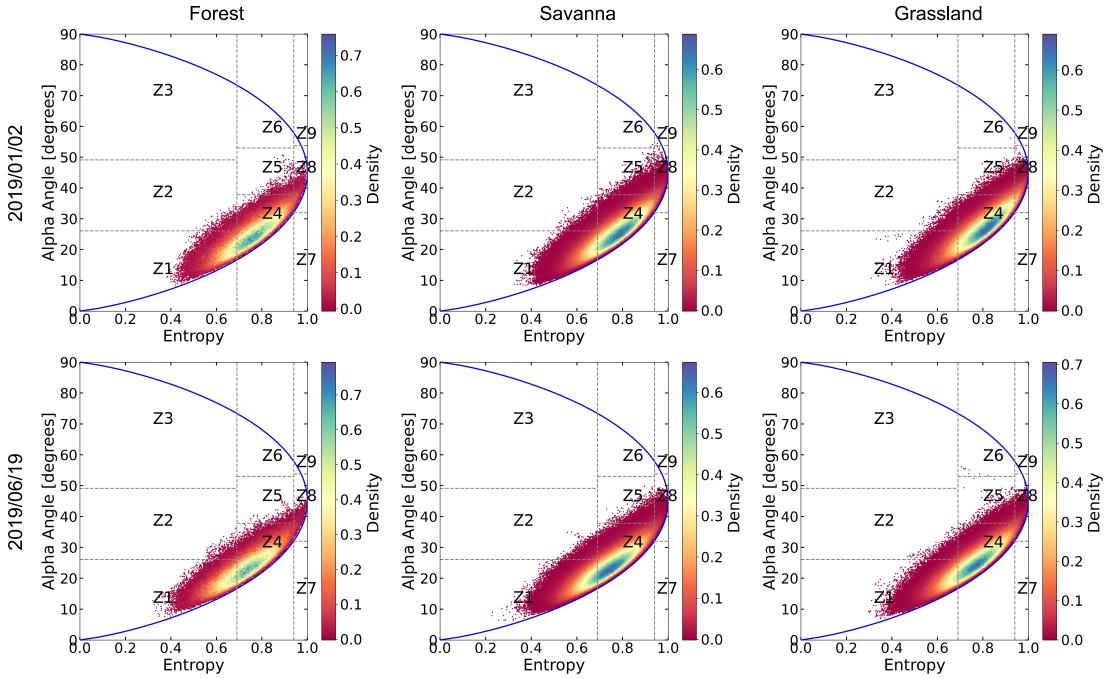


Figura 4: Gráficos de dispersão H- α das classes nas estações úmida e seca. Os exemplos da estação úmida referem-se a 02/01/2019, e da estação seca referem-se a 19/06/2019. A divisão das zonas baseia-se na segmentação proposta por Ji e Wu (2015).

em poucos meses, do perfilhamento ao amadurecimento (WEIß et al., 2021). No fim desse ciclo, as culturas são colhidas, mudando completamente o comportamento de retroespalhamento das áreas cultivadas. Por outro lado, o ciclo fenológico das classes de vegetação de Cerrado dentro do PNB é sazonal, sem a perda de cobertura vegetal e com manutenção de um alto volume de componentes estruturais ao longo dos anos. Portanto, as classes de vegetação do PNB são menos sensíveis às variações dos mecanismos de retroespalhamento do que culturas agrícolas como as de trigo. Esta é também uma possível explicação para os resultados apresentados na Figura 4, para além da influência do ângulo de incidência nas cenas.

A análise do comportamento temporal da entropia e do ângulo alfa para dados de dupla polarização foi conduzida para conhecer como as classes de vegetação estudadas retroespalham o sinal da banda C do Sentinel-1 ao longo das estações. Contudo, essa análise é dificultada uma vez que as zonas que definem os mecanismos de retroespalhamento no gráfico de dispersão H- α apresentam alta sobreposição devido à falta de co-polarização em dados de dupla polarização (JI; WU, 2015). Com isso, as zonas do gráfico de dispersão distinguem até certo ponto apenas zonas de entropia

baixa, média e alta, não discriminando bem zonas de retroespalhamento de superfície, dipolo e retroespalhamento múltiplo (JI; WU, 2015). Nesse caso, a distinção exata e detalhada dos mecanismos de retroespalhamento sobre as classes está além do escopo da informação obtida a partir de dados SAR de polarização dupla, como também está além do escopo deste estudo. Não obstante, perfis temporais de entropia e ângulo alfa foram produzidos como indicadores de primeira ordem das variações sazonais no retroespalhamento das classes. Tais perfis configuraram um conhecimento-base para a interpretação dos perfis temporais dos índices SAR de vegetação.

Os perfis temporais de entropia e ângulo alfa (Figure 5) ilustram as diferenças das classes em relação aos efeitos da sazonalidade na aleatoriedade do sinal de radar e nos mecanismos de retroespalhamento. Em geral, as curvas de mediana de ambos parâmetros polarimétricos aumentaram em meio a uma tendência crescente que tipicamente terminava em meados das estações úmidas. Em seguida, uma tendência decrescente foi observada de forma recorrente entre a segunda metade das estações úmidas e a primeira metade das estações secas. Tal tendência baixava as medianas de todas as classes a aproximadamente o mesmo patamar de valores. Este padrão de comportamento sazonal das curvas de mediana foi observado em todas as três classes, onde estas se desenvolveram em forma de sino (côncava nas estações úmidas e convexa nas estações secas). Este padrão se repetiu em todos os anos analisados em função de mudanças da cobertura do solo desprezíveis no PNB.

A classe *Forest* apresentou um desenvolvimento temporal quase constante, mantendo os menores valores medianos de entropia e ângulo alfa observados dentre as três classes em todos os anos analisados. A estabilidade no comportamento temporal das classes ocorreu possivelmente devido à condição perene de sua cobertura vegetal, uma vez que a estrutura vegetativa não muda significativamente ao longo do tempo e possui altas taxas de umidade relativa abaixo do dossel em função da proximidade a corpos d'água.

A classe *Savanna* mostrou um comportamento temporal similar à classe *Forest*, porém com variações mais pronunciadas em uma faixa de valores de entropia e ângulo alfa intermediária. A classe apresentou ainda uma diferença significativa entre as estações, onde ambos parâmetros polarimétricos foram maiores nas estações úmidas do que nas estações secas. Este comportamento observado ocorreu possivelmente devido à presença misturada de agrupamentos de árvores, arbustos e gramíneas dentro da extensão territorial da classe. Portanto, sua resposta geral foi provavelmente balanceada proporcionalmente à área coberta por cada tipo de vegetação.

A classe *Grassland* apresentou o padrão sazonal mais claro dentre as três classes, variando com os maiores valores de mediana observados ao longo dos anos. Além

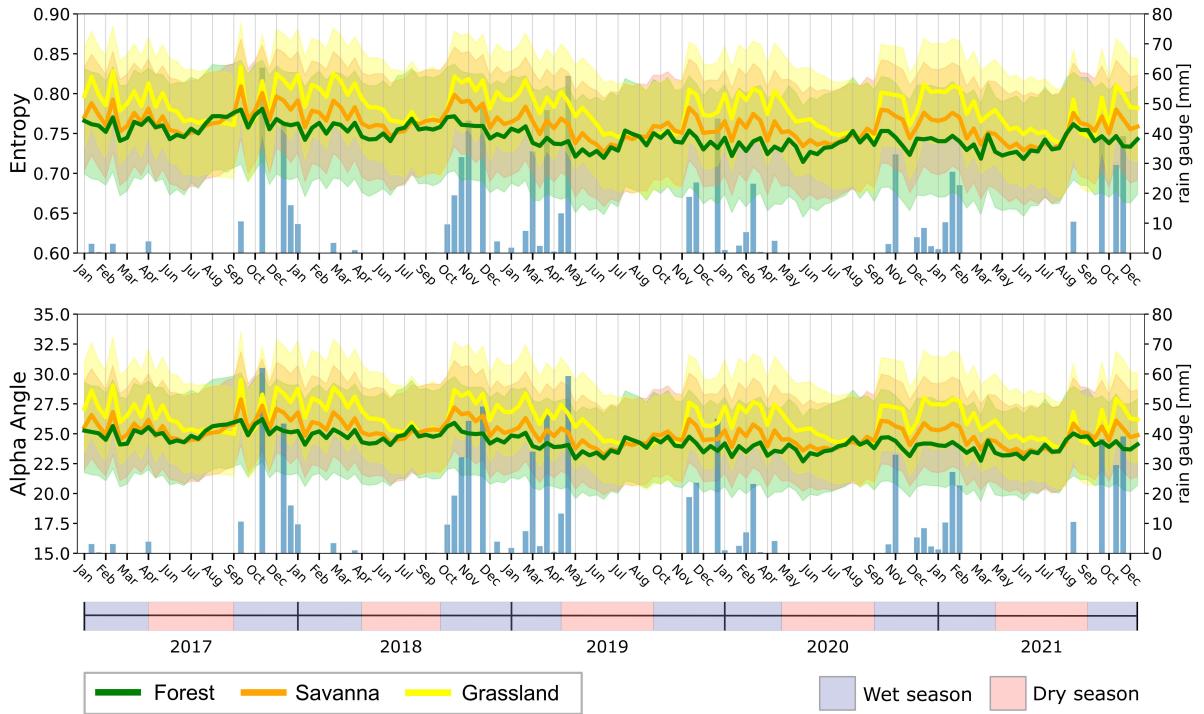


Figura 5: Perfis temporais de entropia e ângulo alfa (em graus) das classes de vegetação do PNB. As linhas representam a mediana espacial em cada data da série temporal. Os polígonos que envolvem as linhas de mediana indicam o intervalo interquartil (IQR) das distribuições espaciais de cada data. As barras azuis ao fundo representam a quantidade de precipitação medida no mesmo dia da aquisição da imagem, na estação pluviométrica da Represa Santa Maria.

disso, a classe apresentou a maior diferença entre as medianas das estações úmidas e secas. Ambos valores de entropia e ângulo alfa foram notavelmente maiores nas estações úmidas do que nas estações secas, evidenciando a forte influência da sazonalidade das chuvas na vegetação da classe.

A influência da sazonalidade na entropia e ângulo alfa das classes foi observado também em termos da resposta desses parâmetros em relação à precipitação. Nas estações úmidas, ambos parâmetros demonstraram sensibilidade à precipitação, fenômeno observado como picos nos dias chuvosos (Figure 5). A amplitude dos deslocamentos das medianas foi diferente para cada classe e data, onde a classe *Grassland* apresentou as maiores amplitudes dos picos, seguida de *Savanna* e *Forest*, respectivamente. A amplitude dos picos variou ao longo do tempo, seguindo as tendências típicas de cada estação. Em cada pico, é possível observar que as curvas de mediana das classes estavam mais distantes entre si, sugerindo um aumento na separabilidade entre as classes.

Outra influência nas curvas de entropia e ângulo alfa pode ter sido as mudanças na estrutura vegetal em função da sazonalidade. O volume de precipitação nas estações

úmidas aumenta a umidade do solo, que leva à rebrota de componentes vegetativos como folhas e galhos (SARMIENTO; MONASTERIO, 1983). A rebrota desses componentes aumenta a complexidade da estrutura vegetal, que leva ao aumento nos níveis de entropia e ângulo alfa. Portanto, a tendência de aumento do início ao meio das estações úmidas pode ser resultante das mudanças na estrutura vegetal das classes. Em contraposição, a perda de componentes vegetais principalmente nas estações secas leva a um decréscimo na complexidade da cobertura vegetal, diminuindo os níveis de entropia e ângulo alfa. Nesse contexto, menores níveis de entropia, tipicamente observados em estações secas, indicam menor despolarização do sinal de radar (HARFENMEISTER et al., 2021) do que nas estações chuvosas. Tal efeito é mais pronunciado quando menor é o nível de biomassa das classes, sendo a classe *Grassland* a mais influenciada por este efeito, seguida por *Savanna* e *Forest*, respectivamente.

A partir dos resultados supracitados, é possível inferir que a precipitação e as mudanças estruturais na vegetação são os principais condutores da resposta temporal da entropia e do ângulo alfa. Nesse contexto, a precipitação conduz principalmente os picos de ambos parâmetros. Por outro lado, o formato das curvas pode estar atrelado com as mudanças estruturais da vegetação das classes em função da influência do regime de chuvas em seus ciclos fenológicos. Com isso, a magnitude das variações das medianas pode ser uma expressão do quanto o sinal de radar muda na interação com a vegetação das classes em função da sazonalidade.

Nas séries temporais de ambos parâmetros, a faixa de valores do IQR foi similar para todas as três classes. As distribuições espaciais de entropia das classes permaneceram em níveis baixos e médios ao longo de todos os anos analisados ($0.66 < H < 0.88$). Este comportamento temporal sugere que os efeitos da sazonalidade nas classes apenas deslocam as distribuições espaciais, não modificando significativamente a dispersão das distribuições ao longo do tempo. As faixas de valores de IQR das classes também denotam um alto grau de sobreposição entre as distribuições espaciais de ambos parâmetros, indicando baixa separabilidade entre as classes apesar da influência da sazonalidade. Tais observações sugerem que a sazonalidade não impacta significativamente a aleatoriedade do sinal de radar na interação com a vegetação das classes estudadas. A persistência dos níveis observados de entropia também indica que a aleatoriedade do sinal de radar é menos sensível aos efeitos das condições ambientais do local de estudo (KIM; ZYL, 2001).

As distribuições espaciais do ângulo alfa permaneceram em baixos níveis em todos os anos analisados ($23.0^\circ < \alpha < 32.5^\circ$). Tais níveis indicam uma maior porção de retroespalhamento de superfície no total retroespalhado pelas vegetação das classes (HARFENMEISTER et al., 2021). Uma possível explicação é o fato de que a rugosi-

dade da superfície e a camada de folhas têm maior contribuição no retroespalhamento total em um ângulo de incidência médio maior ($38,14^\circ$), o que reduz os efeitos da contribuição do retroespalhamento volumétrico no total retroespalhado (MANDAL et al., 2020).

Em suma, a análise da entropia e do ângulo alfa indica que a sazonalidade afeta o mecanismo de retroespalhamento e a aleatoriedade do sinal medido para as classes, de forma inversamente proporcional ao nível de biomassa. Contudo, a influência da sazonalidade apenas desloca as distribuições espaciais para patamares de valores de entropia e ângulo alfa ligeiramente mais altos. Além disso, as curvas de ambos parâmetros mostraram um comportamento onde as distribuições espaciais das classes estiveram altamente sobrepostas ao longo de toda série temporal. Portanto, as três classes estudadas provavelmente não são bem diferenciadas entre si no domínio espacial com base nesses parâmetros polarimétricos. As diferenças entre as classes são percebidas pela amplitude de suas variações em função da sazonalidade das chuvas. Tal comportamento temporal pode ser compreendido como a taxa de variação do sinal da banda C sobre a vegetação das classes ao longo das estações.

4.4 Análise dos coeficientes de retroespalhamento σ_{VH} e σ_{VV}

Para a compreensão da intensidade da resposta de retroespalhamento das classes de vegetação, perfis temporais de σ_{VH} e σ_{VV} foram construídos (Figure 6). As curvas de mediana de ambas polarizações mostraram um comportamento temporal diretamente proporcional ao nível de biomassa das classes, onde a classe *Forest* apresentou os maiores valores de mediana, seguido por *Savanna* e *Grassland*, respectivamente. As curvas de todas as classes se desenvolveram em formato aproximado de sino, indicando um padrão sazonal claro. Dentro deste padrão, as medianas de ambos σ_{VH} e σ_{VV} aumentaram nas estações úmidas e decresceram nas estações secas. As variações em VH e VV foram caracterizadas por tendências crescentes que recorrentemente alcançaram seu pico em meio às estações úmidas, seguidas de tendência decrescentes que comumente findaram em meio às estações secas.

Tais observações evidenciam a sensibilidade do sinal de banda C do Sentinel-1 a diferentes níveis de biomassa vegetal. Contudo, estes resultados contrastam com os resultados reportados por Frison et al. (2018). Os autores não observaram variações sazonais em áreas cobertas por árvores decíduas (Carvalhos) na polarização VV, enquanto observaram variações no perfil temporal da polarização VH. Os padrões sazonais de sua área de estudo foram observados apenas nos perfis de Razão Cruzada (VV/VH), como resultado do decréscimo no retroespalhamento em VH na primavera e

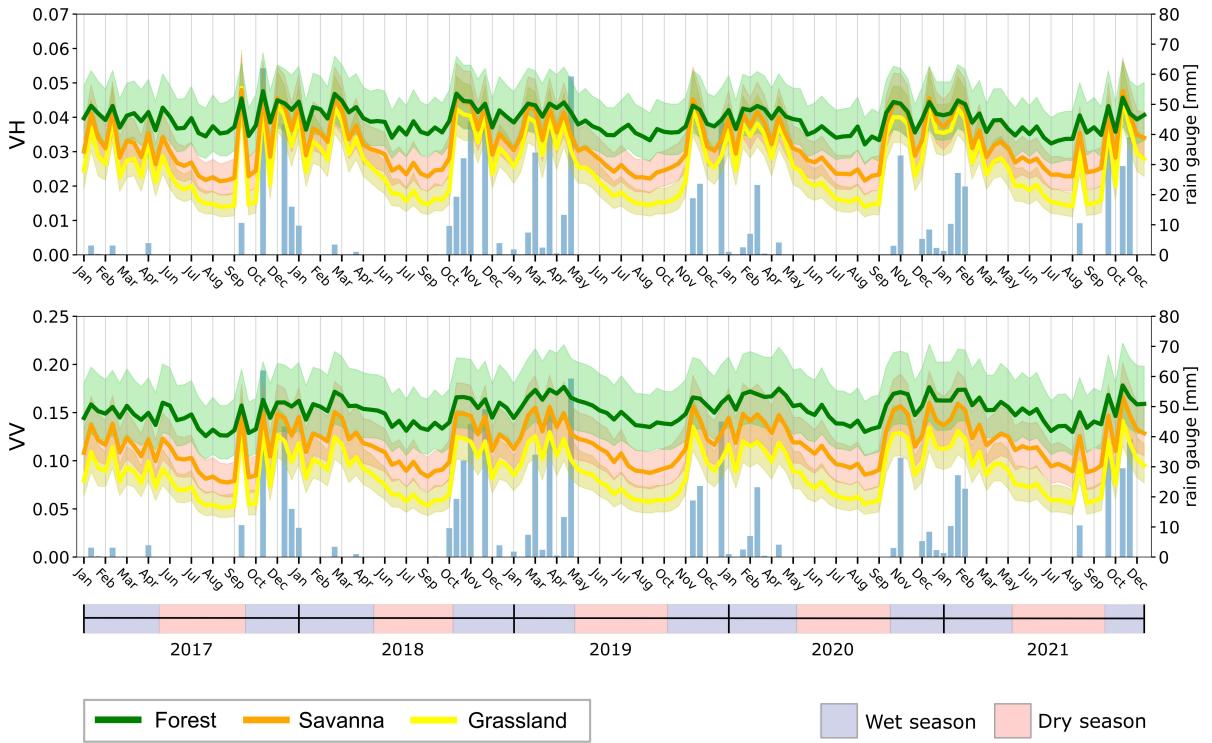


Figura 6: Perfis temporais dos coeficientes de retroespalhamento σ_{VH} e σ_{VV} das classes em escala linear. As linhas representam a mediana espacial em cada data da série temporal. Os polígonos que envolvem as curvas de mediana representam o IQR das distribuições espaciais em cada data. As barras azuis indicam a quantidade de precipitação medida no mesmo dia da aquisição das imagens, na estação pluviométrica da Represa Santa Maria.

no comportamento estável e aproximadamente constante em VV. Os autores também reportam ausência de padrões sazonais no retroespalhamento observado em áreas de coníferas (Pinhos).

Na série temporal, as faixas de intervalo interquartílico para VH e VV foram diferentes em relação ao nível de biomassa das classes. A classe *Forest* apresentou as distribuições espaciais mais dispersas, seguida de *Savanna* e *Grassland*, respectivamente. Tais observações sugerem que, quanto menor é o nível de biomassa da classe, mais homogênea é a distribuição espacial dos coeficientes de retroespalhamento. O desenvolvimento temporal do IQR também sugere que a influência da sazonalidade apenas desloca as distribuições espaciais, não afetando significativamente sua dispersão ao longo do tempo. Além do mais, as distribuições espaciais das três classes apresentam baixa sobreposição nas estações secas. Por outro lado, as distribuições aumentam a sobreposição nas estações úmidas, especialmente em dias chuvosos.

A variação na intensidade de retroespalhamento no decorrer das estações pode ser explicado pela variação na contribuição do solo e da vegetação no total retroespalhado,

assim como as mudanças na estrutura vegetativa e seu conteúdo hídrico (HARFEN-MEISTER et al., 2019). A contribuição da vegetação e do solo são proporcionais ao nível e à densidade de biomassa de cada classe, e são responsáveis pela amplitude das variações nos coeficientes σ_{VH} e σ_{VV} . Nesse caso, quanto menor é o nível de biomassa da classe, maior é a contribuição do solo no total retroespelhado e maior é a amplitude das variações. Por outro lado, as mudanças na estrutura vegetativa e no conteúdo hídrico foram responsáveis pelo formato das curvas de mediana, isto é, as tendências sazonais. Com isso, as mudanças estruturais da vegetação são responsáveis pelas tendências sazonais e a precipitação é responsável pelos picos na série temporal.

O comportamento temporal de retroespelhamento da classe *Forest* apresentou a menor amplitude das variações, onde as medianas de ambas estações úmidas e secas em BH e VV foram similares. Este comportamento pode estar atrelado com o alto nível de biomassa da cobertura vegetal perene dentro da classe ao longo do tempo. Isso se dá pela ausência de mudanças estruturais significativas e ausência de contribuição do retroespelhamento do solo devido à altura das árvores e sua densidade de biomassa. Como reportado por Nizalapur e Madugundu (2010), o sinal de banda C retroespelhado para o sensor tende a saturar com o aumento da biomassa, não sendo capaz de penetrar mais a fundo em coberturas vegetais de níveis de biomassa de aproximadamente 70 tons/ha. Consequentemente, a saturação do sinal da banda C na classe *Forest* limita a interação do sinal com folhas e pequenos galhos na porção superficial da cobertura vegetal densa (sub-bosque). Nesse caso, a resposta de retroespelhamento para a vegetação da classe *Forest* foi primariamente conduzida por mudanças nas propriedades dielétricas da porção superficial da cobertura vegetal.

A classe *Savanna* apresentou variações significativas ao longo do tempo em ambas curvas de mediana de VH e VV, com clara diferença entre as estações úmidas e secas e amplitudes de variação maiores do que a classe *Forest*. A resposta de retroespelhamento mista de árvores, arbustos e gramíneas dentro de seu domínio espacial pode levar a valores de mediana persistentes em uma faixa intermediária ao longo do tempo. Isso se dá pela influência do retroespelhamento do solo, principalmente em regiões com predominância de arbustos e gramíneas. O mesmo ocorre em regiões com predominância de agrupamentos de árvores, porém a predominância de arbustos e gramíneas pode balancear as distribuições espaciais da classe no tempo.

Para a classe *Grassland*, as variações temporais foram as maiores em amplitude para ambas polarizações VH e VV, com medianas das estações úmidas e secas claramente diferentes em função das mudanças sazonais na umidade do solo, estrutura vegetal e conteúdo hídrico. A razão primária da variação nas amplitudes observa-

das para a classe pode ter sido a contribuição do retroespalhamento do solo nessas regiões. A predominância de gramíneas foram mais afetadas pela atenuação do sinal em VV, devido à contribuição direta da rugosidade do solo, umidade do solo e o crescimento vertical de estruturas das plantas (HARFENMEISTER et al., 2019). Tais observações contrastam com os resultados de Frison et al. (2018), que observaram ausência de influência sazonal nas variações do retroespalhamento na polarização VV sobre diferentes estágios de crescimento de pinhos e carvalhos a um ângulo de incidência médio de 40°.

Nas datas chuvosas, as variações na mediana das classes foi observada como picos na série temporal. Os picos mudaram a resposta de retroespalhamento das classes por aumentar os coeficientes a aproximadamente o mesmo patamar. O aumento na intensidade do sinal elevou as medianas das classes a um ponto de saturação comum, que foi aproximadamente 0.20 na polaridade VV e 0.06 na polaridade VH. As distribuições espaciais nessas datas apresentaram altas sobreposições, indicando que a precipitação degrada a separabilidade das classes. Isto ocorreu possivelmente devido à saturação da banda C em função do aumento do conteúdo hídrico na vegetação. Contudo, em outras datas chuvosas, a precipitação não mudou significativamente as distribuições espaciais das classes, possivelmente devido à diferença entre o momento de aquisição da imagem e o momento da precipitação no mesmo dia. Além disso, a distribuição desigual da precipitação na área de estudo pode também ter sido um fator responsável por essas observações, com uma diferença entre a precipitação medida na estação pluviométrica e a precipitação interceptada pela vegetação e a superfície do solo (FRISON et al., 2018).

No processo de análise, foi assumido que o ângulo de incidência foi constante ao longo do tempo. Com isso, as variações temporais no retroespalhamento das classes podem ser atribuídas às mudanças nas características estruturais da vegetação e nas condições de umidade da vegetação e do solo (KELLNDORFER, 2019). Consequentemente, as curvas das polaridades VH e VV para todas as classes sugerem que diferentes contribuições dominam o retroespalhamento durante as estações. Nas estações secas, as variações de retroespalhamento podem ser principalmente atribuídas às mudanças na estrutura vegetal devido a um menor nível de conteúdo hídrico que levou a um decrescimento nos níveis de biomassa das classes. Nas estações úmidas, as variações no retroespalhamento das classes pode ser principalmente atribuídas a duas contribuições distintas. O aumento na umidade da vegetação e do solo foi possivelmente responsável pelos picos de retroespalhamento observados, especialmente nos dias chuvosos. Por outro lado, o aumento de componentes vegetativos provavelmente foi o responsável pelas tendências crescentes nas medianas das estações

úmidas.

Os resultados supracitados podem ser explicados pelas limitações inerentes de sistemas SAR que operam na banda C para estudos de vegetação. O sinal de banda C retroespalhado de volta ao sensor tende a saturar com o aumento da biomassa, não sendo capaz de penetrar mais a fundo na cobertura vegetal em níveis de biomassa de aproximadamente 70 tons/ha (NIZALAPUR; MADUGUNDU, 2010), com a saturação do sinal ocorrendo em biomassas por volta de 30–50 tons/ha (QUEGAN et al., 2000). Nesse caso, os efeitos de saturação do sinal de banda C ainda podem ser observados nos perfis temporais. Além disso, de acordo com Saatchi (2019), a precipitação interceptada pela cobertura vegetal gera gotas de água nas folhas que causam a dispersão e a atenuação do sinal de radar, especialmente na banda C.

Trabalhos futuros podem aproveitar as características de sensores na banda L tais como a constelação SAOCOM (Satélite Argentino de Observación Con Microondas), BIOMASS (ESA) e NISAR (NASA-ISRO SAR), com expectativa de lançamento para o ano de 2023. Os dados de banda L permitem superar os efeitos de saturação nos coeficientes de retroespalhamento, provavelmente melhorando a capacidade de distinguir diferentes níveis de biomassa em áreas de vegetação densa, como no caso das fitofisionomias do Cerrado.

Em resumo, os perfis temporais das polarizações VH e VV demonstram que a sazonalidade tem uma influência significativa na intensidade do retroespalhamento medido nas classes ao longo do tempo. Os resultados indicam uma relação diretamente proporcional entre os coeficientes de retroespalhamento VH e VV e o nível de biomassa das classes. Além disso, as distribuições espaciais das classes para ambas polarizações apresentaram menores sobreposições do que as variáveis polarimétricas entropia e ângulo alfa. Consequentemente, as classes de vegetação foram melhores discriminadas entre si pela intensidade do sinal. Tais resultados sugerem que os índices SAR de vegetação podem descrever melhor as diferenças entre as classes pelo nível de biomassa.

5 PARTE II - Análise dos índices SAR de vegetação

Esta seção foi desenvolvida em formato de um artigo que trata do comportamento espaço-temporal de cinco índices SAR de vegetação: DpRVI, RVI, PRVI, DPSVI e DPSVIm em três classes de vegetação de Cerrado: *Forest*, *Savanna* e *Grassland*. O artigo se inicia com a análise e interpretação de perfis temporais de mediana, intervalo interquartil e desvio padrão, que representam as distribuições espaciais das classes em cada data da série temporal. As análises contemplam ainda a interpretação visual de mapas que exemplificam a resposta dos índices SAR nas estações úmidas e secas. Tais análises foram desenvolvidas com o objetivo de retratar a resposta espaço-temporal dos índices SAR em relação à influência da sazonalidade do regime de chuvas no Parque Nacional de Brasília, tendo como premissa básica mudanças na cobertura do solo desprezíveis. Além disso, tais análises serviram como um panorama do nível de separabilidade entre as classes em cada estação.

O artigo trata ainda de uma análise do nível de separabilidade entre as classes de vegetação baseada em um teste de hipótese sobre distâncias estocásticas de Kullback-Leibler. Esta análise teve por objetivo verificar a influência da sazonalidade na proximidade de distribuições espaciais amostrais das três classes, onde foi possível verificar o período em que as classes se tornam mais distinguíveis. De um modo geral, o emprego de um teste sobre distâncias estocásticas visou falsear as hipóteses levantadas na análise dos perfis temporais.

O artigo foi escrito em língua inglesa, sob o título "*Understanding the spatio-temporal behavior of Sentinel-1 SAR vegetation indices over the Brazilian Savanna*". O objetivo principal de adoção desse formato foi submeter o trabalho em revista internacional revisada por pares, a *Remote Sensing of Environment*. Além dos resultados, o artigo ainda traz a prova matemática da métrica de distância estocástica de Kullback-Leibler entre duas distribuições log-normais e um *link* que leva à toda estrutura de código Python desenvolvida para a produção dessa dissertação.

Understanding the spatio-temporal behavior of Sentinel-1 SAR vegetation indices over the Brazilian Savanna

Abstract—The Cerrado biome has been under pressure by the expansion of the agriculture frontier in recent years. The Brazilian government's methodological strategies for monitoring deforestation in the biome uses mainly multispectral satellite imagery, whose availability and quality are constrained by the cloud cover in the scenes. The optical data limitation to provide dense time series over the years raises the need for alternatives for the continuous monitoring of preserved areas. In this context, various studies investigated the potential of SAR data to monitor the Cerrado vegetation due to its cloud-free characteristic, high revisit frequency, and wide spatial coverage, which allows continuous monitoring of the Brazilian savanna physiognomies. In the recent years, the increasing availability of open SAR data led by the Sentinel-1 mission allowed the development of various dual-pol SAR vegetation indices as vegetation descriptors, most of them focused on crop monitoring. However, to the best of our knowledge, studies that investigate the use of SAR vegetation indices to map and monitor the Cerrado biome have not been addressed so far. In this study, the temporal behavior of five SAR vegetation indices derived from Sentinel-1 data was investigated in the period between 2017 and 2021 for three vegetation classes (Forest, Savanna and Grasslands) in the Brasilia National Park, Brazil. Temporal profiles analysis showed that DpRVI, RVI, PRVI, DPSVI, and DPSVIm follows a seasonal pattern directly linked with the rainfall regime in the study site. DpRVI, and RVI were found related to the rate of radar signal variation over the vegetation as a function of the seasonality influence. PRVI, DPSVI, and DPSVIm were found directly related with the biomass level of the classes and its variations over time. Precipitation and seasonal vegetation structure changes were found to be important drivers of the shift and the spread of the indices' spatial distributions over time. In this regard, a phenomenon here called index equalization was observed on rainy dates, shifting and spreading all classes' spatial distributions to the same indices' value ranges; consequently degrading the separability between classes. A hypothesis test based on stochastic distances analysis demonstrated that the similarity between classes increases in the dry seasons and decreases in wet seasons. The DpRVI and RVI H₀ rejection curves remained above 97% without a clear seasonal pattern. The PRVI, DPSVI, and DPSVIm curves for pairs of classes showed rates H₀ rejection above 94% within a seasonal pattern.

Index Terms—Cerrado, C-band, time series, stochastic distances

I. INTRODUCTION

THE Brazilian Cerrado has already lost almost half of its original cover. This is what recent studies conclude about the land use of the second largest biome in South America [1] [2]. Occupying approximately 2 million km² (about 24% of Brazil's total area), the biome is the world's most biologically diverse savanna [3], hosting more than 12,000 plant species [4] and one third of Brazilian diversity, with a high level of endemism [5]. Considered one of the

34 hotspots for biodiversity conservation [6], the biome is under human-induced pressures related with the expansion of the agricultural frontier [1], especially on a region known as MATOPIBA (region that encompasses the Brazilian states of Maranhão, Tocantins, Piauí, and Bahia) [7]. Those four states were jointly responsible for 55% of native vegetation loss between 2005 and 2017 [8].

The Cerrado map of 2021, produced by the MapBiomass¹ project, indicates that approximately 53% of the total Brazilian Cerrado extent was mapped as a natural vegetation landscape in this year. The map also shows approximately 46% of Cerrado mapped as different anthropic uses, mainly agriculture, aquaculture, and mining. In terms of deforestation, Brazil's continuous data-based monitoring programs of clear-cut deforestation (PRODES) data in Terra Brasilis portal [9] shows an increasing trend in vegetation suppression in the period between 2019 and 2022, where a total of 10700 Km² of deforested area was detected. Furthermore, in 2022, the Cerrado Deforestation Alert System (SAD-Cerrado) reported 91768 deforestation alerts over an area of 8155,32 Km², mostly on the MATOPIBA region [10].

Those Brazilian strategies to monitor Cerrado mainly encompass satellite optical imagery to map the temporal dynamics of Cerrado. However, this approach to monitor deforestation has many challenges regarding the availability of multispectral cloud free imagery. The Cerrado domain has a well marked climatic seasonality with 6-month-long dry seasons and 6-month-long wet seasons [11]. Furthermore, the characteristic vegetation along the Cerrado territory is a mosaic of different proportions of evergreen riparian forests, deciduous and semi-deciduous forests, savanna woodlands, shrublands, and grasslands, with highly seasonal dynamics [11].

Within this context, SAR systems are attractive for mapping and monitoring vegetation cover changes since they can acquire images despite the cloud coverage and solar illumination conditions of the Earth surface. In the past, different studies investigated the potential of SAR data for Cerrado vegetation mapping and monitoring [12] [13] [14] [15] [11] [16] [17]. Most studies use backscattering information to characterize different vegetation types within Cerrado and in different regions.

In recent years, the increasing availability of SAR data leaded by the European Space Agency (ESA) SAR-C Sentinel-1 mission led researches worldwide to develop SAR vegetation indices, most of them focusing on monitoring agricultural

¹(<https://plataforma.brasil.mapbiomas.org/>)

crops [18] [19] [20] [21] [22]. SAR vegetation indices are mathematical models that take advantage of the polarimetric properties of the interaction between the radar signal and the vegetation canopies to enhance the contrast between vegetation and other distributed targets, simplifying the analysis of SAR imagery. However, to the best of our knowledge, studies investigating the use of SAR vegetation indices to map the Cerrado vegetation have not been addressed yet.

Following the presented context, this study raises the scientific question: how the dual-pol SAR vegetation indices describes the vegetation of Cerrado in preserved areas? The question is based on the premise that, by knowing and understanding the seasonal dynamics of a preserved Cerrado region in terms of SAR data, it is possible to better identify and interpret possible disturbances in the future. Thus, the main purpose of this work is to investigate the potential of the dual-pol SAR vegetation indices as indicators of the seasonal dynamics over the Cerrado vegetation.

As an attempt to answer the question, the spatio-temporal behavior of five Sentinel-1 SAR vegetation indices is explored in this paper to understand the indices' spatial distributions and temporal trends within the Brasilia National Park (BNP) - Brazil. The separability level between three physiognomies in the study site was also assessed to gain knowledge about how seasonality influences the indices' spatial distributions over time.

II. METHODOLOGY

A. Study site

This present research's study site is the Brasilia National Park (BNP), a 30,000 hectare preserved area inside the Cerrado biome, located on the north-western region of Brazil's Federal District (Figure 1). The park is an important savanna research and conservation site, since its area encompasses the major physiognomies of the Brazilian Cerrado [13].

The seasonal dynamics in BNP is characterized by a wet summer, from October to April, and a dry winter from May to September [12], as indicated in Figure 1. The described seasonal pattern was adopted in this study as an analysis unit to evaluate the influence of the rainfall regime on the performance of the SAR vegetation indices. Moreover, the BNP relief can be considered near-flat to smoothly undulated, according to the EMBRAPA slope classification system [25]. About half the SRTM DEM pixels in BNP's extent are below 8 degrees. Thus, in this study, the relief influence in the SAR backscattering response was assumed negligible.

Since the research location is a protected region, no substantial changes to land cover over time were assumed. Therefore, the BNP vegetation is referenced in this study as classes that represent three major Cerrado physiognomies present within the park extent. Sorted by decreasing above-ground biomass content [24], the classes are: Forest (FT), Savanna (SL), and Grassland (GL), following the definition proposed by [26]. In this paper, the term "biomass level" does not refer directly to above-ground biomass of the vegetation. The term is used to summarize the differences between the classes' vegetation structure composition.

The spatial extents of the classes were extracted from the MapBiomas Collection 6 2020 LULC produced with Landsat 8 imagery. The classes' spatial extent were vectorized following the map legend code id's (Forest = 3, Savanna = 4, and Grassland = 12). The collection 6 maps is reported to present 74.9% of global accuracy on the Cerrado biome [27].

In BNP, the Forest class is represented by the Gallery Forests physiognomy (Figure 1). This vegetation unit is present alongside brooks and streams as closed corridors of high trees above water courses. The Gallery Forests are characterized mainly by semi-deciduous to evergreen trees with 20-30m average height with complex vegetation canopies [26] [17]. The regions covered by Gallery Forests present 40-70% of arboreous cover in the dry season and about 50-90% in the wet season, forming a continuous dense canopy cover with high rates of relative moisture all over the seasons [26] [12].

The evergreen condition of Forest-class vegetation maintains nearly constant high volumes of vegetation components like broad leaves and medium-sized branches in a dense and stable upper canopy. Due to the canopy's continuous dense biomass and tree heights, the C-band signal interactions are likely limited to the upper canopy components like leaves and branches. In this case, there is often a saturation of the C-band over the Forest class, with no underlying soil contributions to the total backscattered signal in those regions.

The Savanna class encompasses two Cerrado physiognomies: Savanna Woodland and Wooded Savanna [26] [23] [12]. The Savanna Woodland is characterized by a mix of grasses, shrubs, and sparse trees. Its trees can reach an average height of 3-6m with an arboreous cover of around 20-50%, forming a discontinuous canopy cover across the territory. The Wooded Savanna phytophysiology can be described as a shrubland with sparse trees. The trees can reach an average height around 2-3m and 5-20% of arboreous cover. This vegetation unit represents the lowest and least dense form of the Savanna subgroups, with predominance of shrubs and herbs.

The mixture of those two physiognomies within Savanna results in a continuous shrub-herbaceous layer with a discontinuous tree layer composed of xeromorphic semi-deciduous to evergreen trees agglomerated in various densities across the territory [17] [24]. Hence, some C-band signal saturation is expected in areas of clusters of trees and where the composition tree-shrub-herbs density is higher. In regions where the vegetation composition is less dense and sparse, some scattering contribution from the underlying soil is expected.

The Grassland class in BNP contains two Cerrado physiognomies, characterized by a predominance of grasses without woody vegetation cover [26] [12] [17]: Shrub Savanna and Savanna Grassland. The Shrub Savanna is composed by the sparse presence of shrubs and herbaceous plants within a open grassland. The shrubby vegetation can reach an average height of 2m and less than 5% of arboreous cover. The grasses and herbaceous plants can reach an average height of 0.5 m. The Savanna Grassland physiognomy is defined as an open grassland with predominance of herbaceous plants and grasses, rare occurrence of shrubs, and the complete absence of trees.

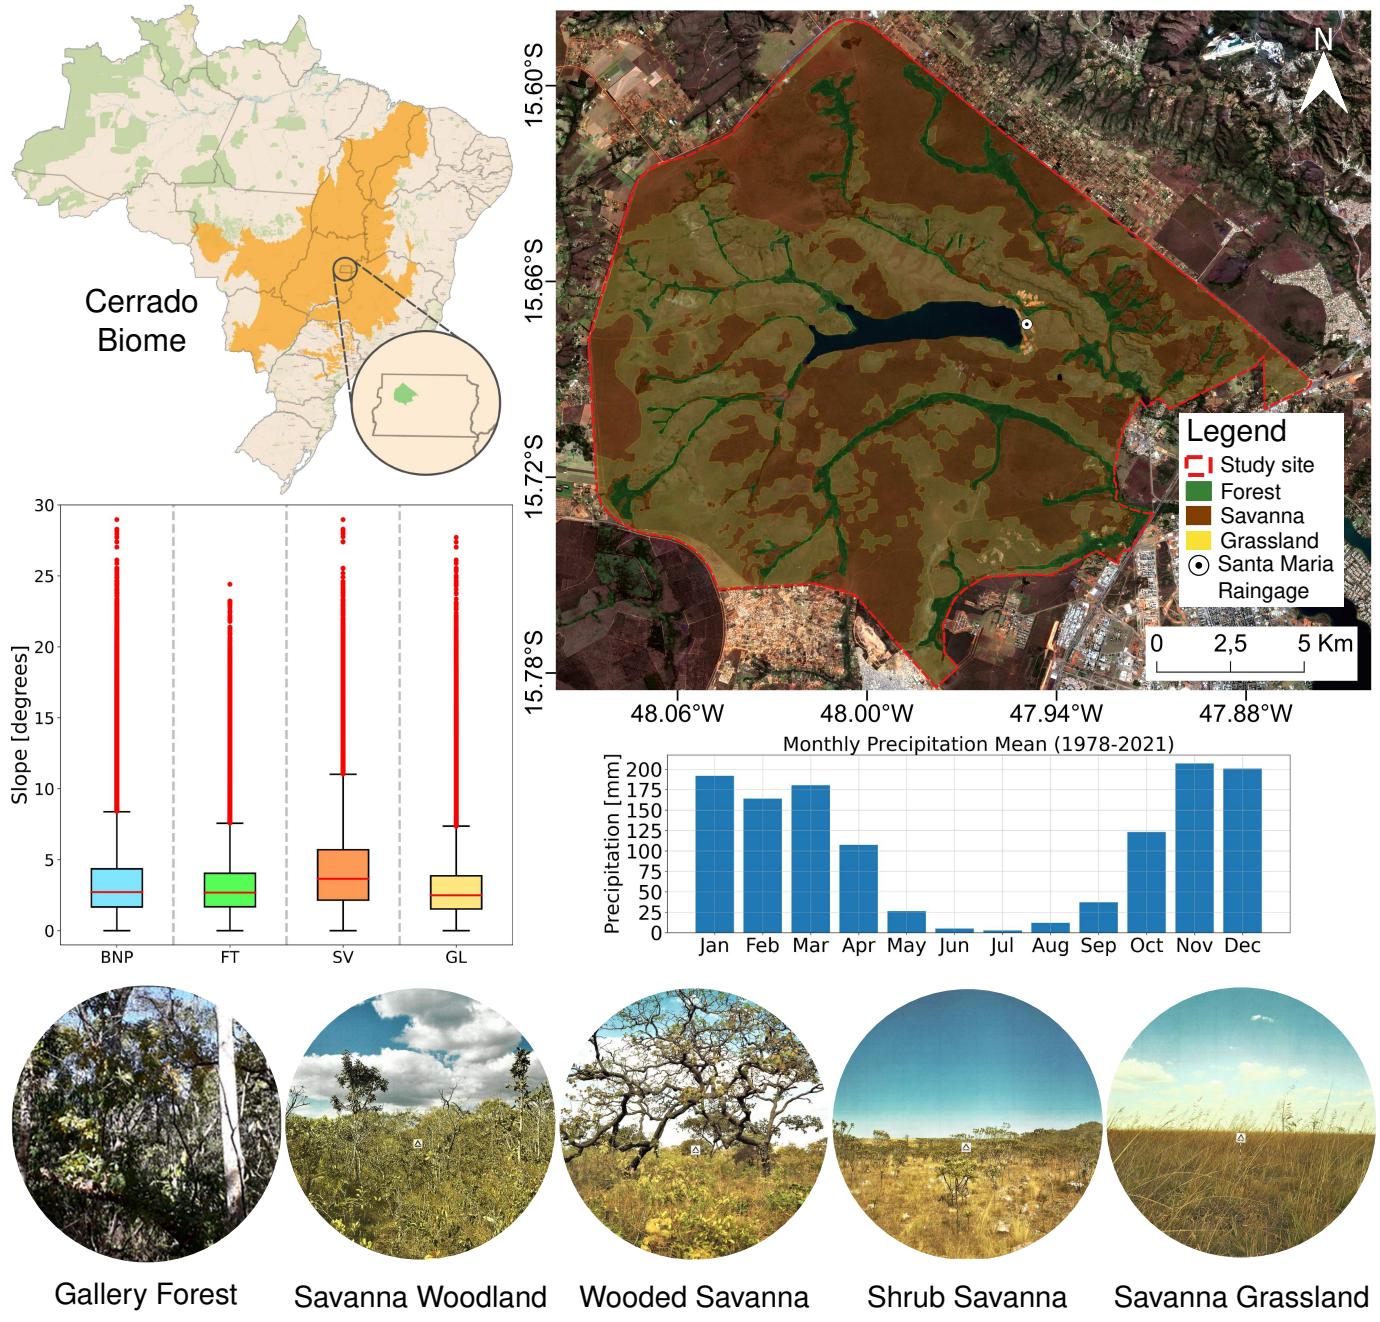


Fig. 1. a) Localization of BNP within the Cerrado biome; b) Study site map presenting the classes spatial extents. The basemap is a Sentinel-2 image from 06/07/2020 (RGB 4-3-2). c) The Santa Maria rain gauge average monthly precipitation (1978-2021) data was obtained from the Hidroweb platform (www.snirh.gov.br/hidroweb/); d) The BNP and classes slope distributions were extracted from SRTM 1 arcsecond (30 meters) DEM obtained from the Earth Explorer platform; e) The pictures are examples of each class vegetation taken from [23] and [24].

Its vegetation cover can reach the mean height of 0.7 m, with grass inflorescences that can reach 2.5 m [23].

The herbaceous plants present seasonal marked phenological cycles. Its most vigorous phase occurs in the wet season, with the germination of new plants and the regrowth of the established ones by the sprouting of new leaves and stems [28]. Because of its shallow roots, the water restriction in the dry season hinders the plant's growth and leads to its desiccation, consequently establishing a dry biomass within Grassland [29]. Over the Grassland vegetation, scattering contributions are

expected from both the plants and the underlying soil due to low grass heights and biomass density. In this case, its seasonal backscattering response reflects contributions both from the vegetation structure and water content as also from the soil roughness and moisture.

B. SAR vegetation indices

1) **Dual-pol Radar Vegetation Index (DpRVI):** The DpRVI can be defined as a measure of scattering randomness from vegetation structures [22]. The index is calculated as a function

of the degree of polarization (DOP) and a parameter that measures the dominance in the scattering mechanism (β).

The DOP is the ratio between the average intensity of the polarized portion of the wave and the average total intensity of the wave [22]. The β parameter indicates the contribution of the dominant scattering component within the total backscattered power. This information is calculated from Sentinel-1 SLC products by deriving the elements of the C_2 matrix calculated, which are related with the second-order scattering information generated from the spatial averaging within a kernel [22]. In this study, the DpRVI was generated with a 5x5 kernel.

The DOP is derived from the C_2 matrix by using Barakat's expression [30]. The value of DOP varies between 0 and 1, where $DOP = 0$ refers to a completely unpolarized wave state and $DOP = 1$ refers to a completely polarized wave state. In between those values, the wave is considered in a partially polarized wave state, $0 < DOP < 1$. For dual-pol, the DOP is equivalent to wave anisotropy, which is the relative strength between the first and the second dominant scattering mechanisms [22].

$$DOP = \frac{\text{Polarized Power}}{\text{Total Power}} = \sqrt{1 - \frac{4 \times \det([C_2])}{(\text{Trace}[C_2])^2}} \quad (1)$$

The parameter of scattering mechanism dominance (β) is derived from the eigen-decomposition of the C_2 matrix [22]. The two non-negative eigenvalues, which quantifies the dominance of scattering mechanisms, are normalized with the total power span ($\text{Tr}(C_2) = \lambda_1 + \lambda_2$).

$$\beta = \frac{\lambda_1}{\lambda_1 + \lambda_2} \quad (2)$$

The formulation of DpRVI is a product of the DOP subtracted by the unit and β parameter. The product of DOP and β corresponds to the scaling of the dominant scattering [22]. The index is bounded between 0 and 1, with both the lower and upper bounds having physical significance.

$$DpRVI = 1 - DOP \times \beta, \quad 0 \leq DpRVI \leq 1 \quad (3)$$

2) *Radar Vegetation Index (RVI)*: Originally formulated for full polarimetric data, the RVI was widely used as parameter to identify and separate vegetated areas from bare soil surfaces, since the index is sensitive to the biomass level [31]. The index was also reported to be related to Vegetation Water Content (VWC), which is directly linked to vegetation wetness [32].

RVI is based on modeling vegetation structure as a collection of randomly oriented dipoles [33]. The index formulation is a measure of the randomness of the signal scattering, by addressing the contribution of volume scattering to the total backscattered power, indicated by the cross-polarized backscattering coefficients [20].

The adaptation of RVI for dual-pol SAR data was first studied by [34], assuming that the contribution of the interaction between soil and vegetation in the total backscattered wave is disposable. The modification was proposed according to

an assumption that supposes $\sigma_{hh}^0 \approx \sigma_{vv}^0$ [35]. Similarly, an implementation of the index with VV and VH polarizations of Sentinel-1 dual-pol data was proposed by [20].

$$RVI_{S-1} = \frac{4\sigma_{vh}^0}{\sigma_{vv}^0 + \sigma_{vh}^0} \quad (4)$$

3) *Polarimetric Radar Vegetation Index (PRVI)*: The index was proposed as an indicator of shrubland biomass [18]. The index encompasses the degree of polarization and the cross-polarized backscatter intensity to characterize the scattering from vegetation structures. By addressing vegetation as a signal-depolarizing media, the index uses the unpolarized portion of the scattered wave by subtracting the DOP from unity, which is considered to represent the volume scattering component from distributed targets [36]. Then, this parameter is multiplied by the cross-polarized backscattering intensity, turning it into an unbounded index.

The original formulation of PRVI encompasses the DOP calculated by the modified Mueller matrix with Stokes parameters from full polarimetric SAR data, assuming a completely and linearly polarized wave emitted by the sensor [18]. However, these parameters are inaccessible for dual-polarimetric data. Hence, for a dual-polarimetric implementation of PRVI, the DOP can be calculated by Barakat's expression from the C_2 matrix, as well as DpRVI [37]. Moreover, the C_{22} element of the C_2 matrix can be used as the cross polarized backscattering intensity.

$$PRVI = (1 - DOP) \times \sigma_{vh}^0 \quad (5)$$

4) *Dual Pol SAR Vegetation Index (DPSVI)*: This SAR vegetation index was proposed to assess the scattering behavior of different surface targets in terms of the co- and cross-polarized backscatter intensities of Sentinel-1 data [19] derived from GRD products.

Its theoretical model is based on the approximately triangular shape of the two-dimensional scatter plot between σ_{vv}^0 and σ_{vh}^0 . The plot expresses the behavior of different surface targets, such as vegetation (upper left portion), soil (lower right portion), and water bodies (lower left portion). The distribution of these different targets within the plot follows the concept of degree of depolarization, in which the signal transmitted by the sensor experiences some depolarization in the interaction with the target's surface. The index is a function of the Inverse dual-pol Diagonal Distance (IDPDD), the Vertical Dual Depolarization Index (VDDPI), and the backscattering coefficient of VH (σ_{vh}^0).

The IDPDD is a measure of the inverse diagonal distance of Soil-Vegetation Edge, a conceptual measure introduced by [19] that represents the soil in its lower range and vegetation in its upper range.

$$IDPDD = \frac{(\sigma_{vv_{max}}^0 - \sigma_{vv}^0) + \sigma_{vh}^0}{\sqrt{2}} \quad (6)$$

The $\sigma_{vv_{max}}^0$ term in IDPDD needs to be assessed to avoid the influence of the high backscattering regions, i.e. regions oriented in such a way that it scatters the entire transmitted signal back to the sensor [19]. In this study, the $\sigma_{vv_{max}}^0$ was

assessed by analyzing the scatter plots of a few images from the wet and dry seasons. The $\sigma_{vv_{max}}^0$ was considered inside the approximated core region of the scatter plots and its value was taken as 10 for the calculation of DPSVI.

The VDDPI index estimates the degree to which the target's surface depolarizes the transmitted signal, given by the ratio between the total polarized power and the co-polarized power [19].

$$VDDPI = \frac{\sigma_{vv}^0 + \sigma_{vh}^0}{\sigma_{vv}^0} \quad (7)$$

The final formulation of DPSVI integrates the σ_{vh}^0 to make the index range start from water bodies in the lowest values to vegetation in the highest values, where the index values increase with the increased amount of above ground-biomass.

$$DPSVI = IDPDD \times VDDPI \times \sigma_{vh}^0 \quad (8)$$

5) *Modified Dual Pol SAR Vegetation Index (DPSVIm)*: The index was proposed as a modification of the original DPSVI to improve its capacity to monitor dense vegetation areas such as the Brazilian Atlantic Forest biome [21]. The main motivation for the DPSVI modification is that the index was developed for regions of dense and sparse crops [19], and its applicability to dense vegetation regions were unknown until then.

The first modification on DPSVI is based on the tendency of IDPDD to saturate in dense biomass regions [19]. Hence, IDPDD was replaced by DPDD (Dual Polarization Diagonal Distance), which was reported to be more appropriate to represent dense vegetation features like forests [19].

$$DPDD = \frac{\sigma_{vv}^0 + \sigma_{vh}^0}{\sqrt{2}} \quad (9)$$

The second modification on DPSVI formulation was the replacement of VDDPI by Cross Ratio (CR) [38], which is reported to have an exponential behavior as a function of VDDPI and to be better suited to distinguish pixels of vegetation [21].

$$CR = \frac{\sigma_{vv}^0}{\sigma_{vh}^0} \quad (10)$$

The formulation of DPSVIm is a function of DPDD, CR, and the σ_{vh}^0 , and is an unbounded index. The index has presented correlation and agreement with above-ground biomass from Atlantic Forest fragments, and in near-flat areas, it was capable to distinguishing plots with biomass of approximately 50.0 Mg/ha from those with approximately 200.0 Mg/ha [21].

$$DPSVIm = DPDD \times CR \times \dots \quad (11)$$

C. SAR data and preprocessing pipeline

To derive the necessary data to compute the SAR vegetation indices, SAR-C Sentinel-1A products were used. The products were acquired by the Interferometric Wide Swath (IW) mode in the descending orbit 14796, with an average incidence angle of approximately 38.14°. The temporal dataset was composed by all available Single Look Complex (SLC) and Ground

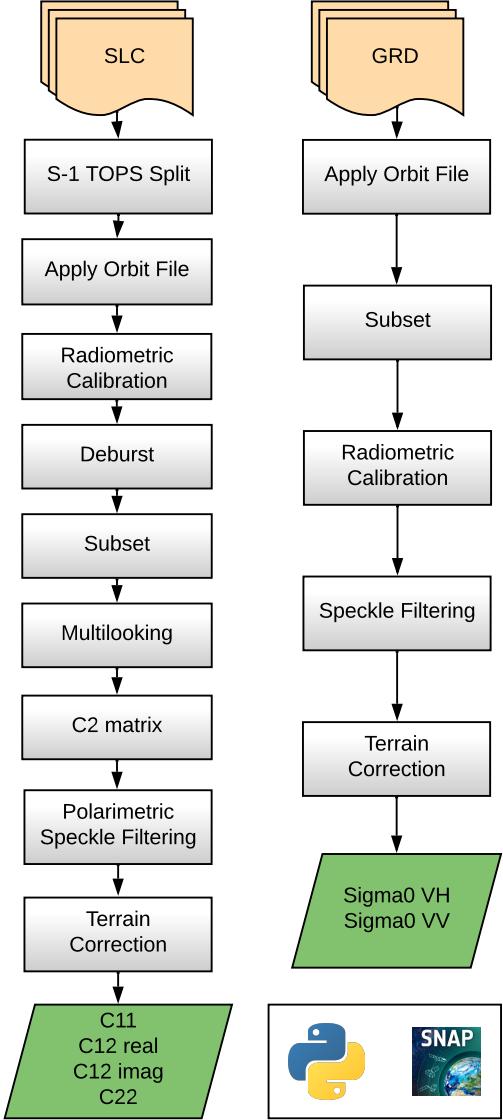


Fig. 2. Preprocessing pipelines for Sentinel-1 SLC products implemented in Python using the SNAP API for Python.

Range Detection (GRD) products on the Alaska Satellite Facility (ASF) platform from January 2017 to December 2021, totaling 149 scenes of each product type acquired with 12 days of revisit time. The SLC products were used to calculate DpRVI and PRVI; and the GRD products were used to calculate RVI, DPSVI, and DPSVIm.

The preprocessing pipelines for both product types are presented in Figure 2. Each pipeline was executed in a fully automated batch mode, applied on each image separately by a Python script that implements the SNAP operators using its Python module snappy. The link to access the source codes is presented in Appendix A.

1) *C₂ matrix components*: To obtain the C_2 matrix components, firstly, the swaths and bursts of the SLC products that intersect the study site were identified. Its code parses the XML metadata of Sentinel-1 .SAFE files and retrieves the scenes swaths and bursts geometries, using the Python

library S-1 TOPS Split Analyzer. The identified swaths and bursts were used as parameters for TOPS Split operator. Then, the orbit state vectors were updated with precise orbit files. Subsequently, the products were radiometrically calibrated and the output was saved in a complex-valued format. The calibrated products were then debursted and cropped using the study site spatial extent. The products were then multilooked by 4x1 in range and azimuth directions to generate ground range square pixels. The C_2 matrix components were produced and then were speckle-filtered with the polarimetric Refined Lee filter [39] with a 3x3 kernel.

Finally, the C_2 matrix components were geocoded by Range Doppler Terrain Correction operator into a UTM projected coordinate system (EPSG:32722) and re-sampled to 10 m of pixel spacing with a bilinear interpolation algorithm. The final product was a Geotiff file with the C_2 matrix components (C_{11} , $\Re(C_{12})$, $\Im(C_{12})$, C_{22}) expressed in power linear units.

2) Backscatter Coefficients: To derive the backscatter coefficients, firstly, preliminary comparisons between GRD products provided by the European Space Agency (ESA) and GRD data derived from SLC products were made. The comparison of both GRD products do not showed significant differences between the backscattering coefficients. The processing of GRD data from SLC products allows more control on the preprocessing parameters, at the cost of more complex and extra steps to obtain the backscattering coefficients than the GRD products provided by ESA. In this case, the adoption of the GRD products provided by ESA was a based on its simpler preprocessing pipeline to obtain approximately the same result than deriving the GRD from the SLC imagery. Hence, in this study, the backscatter coefficients were derived from the GRD products provided by the European Space Agency (ESA).

To calculate the σ_{VH}^0 and σ_{VV}^0 backscatter coefficients, the first step was to update the orbit state vectors of the GRD products. Then, the imagery was clipped to the spatial extent of the study site. The radiometric calibration was applied to the amplitude imagery of VH and VV. In sequence, the speckle filtering was performed by Refined Lee filter with a 3x3 kernel. Finally, the imagery was geocoded by the Range Doppler Terrain Correction operator. The final product was a Geotiff file containing σ_{vv}^0 and σ_{vh}^0 with 10m of pixel spacing, expressed in power linear units.

D. Data sampling and analysis

First and foremost, all indices were calculated in a fully automated process implemented on a Python script. The script was constructed to calculate the indices from the SLC and GRD preprocessed products and stack the result in the same raster file for each date. The source codes can be accessed in the Appendix A.

Then, the indices' zonal statistics such as median, upper quartile, and lower quartile were extracted within the classes' spatial extents. In this process, a 20 m negative buffer was applied on the classes vector borders to avoid interference of the classes mixture due to the scale difference between the Sentinel-1 data and the classes' spatial extents.

To analyze the temporal variation of the SAR vegetation indices and observe its general trends, the spatial median

values with a surrounding polygon representing the interquartile ranges (IQR) of all classes per date were plotted and interpreted. Hence, the temporal profiles are a representation of the SAR vegetation indices' spatial distributions variation over time.

In the temporal profiles analysis, the term "separability" was used to represent the degree of distinction between vegetation classes off different biomass level which the indices can separate. The parameter to observe the classes separability was the overlap between spatial distributions of the classes, i.e. the overlap between IQR polygons around the medians. Technically, a high overlap between the classes' distributions means that they are not easily distinguished from each other, and vice-versa.

Lastly, a hypothesis test based on the Kullback-Leibler stochastic distances proposed by [40] was employed to better understand how distinguishable the classes are from each other over the seasons. A stochastic distance is the distance between two probability distributions and its concept is based on divergence measures. Divergence measures are coefficients that reflect how close or far apart two distributions are from each other, with the property of becoming larger as the difference between distributions increases [41]. The majority of these coefficients lack the property of symmetry and so are not truly distance metrics [41]. However, their symmetric variants are known as stochastic distances [40], which are useful for comparing random variables since further distributions are easier to distinguish than closer ones.

The Kullback-Leibler stochastic distances can be interpreted as the separability between two distributions, since smaller distances denote a higher degree of statistical similarity of the probability density functions (PDF) [42]. The use of this method to assess the separability between classes is based on the assumption that different responses of the SAR indices regarding biomass level produce different spatial distributions throughout the seasons. Based on this, the null hypothesis (H_0) of the test is that two sample distributions obtained in different regions can be described by the same distribution ($\hat{\theta}_p = \hat{\theta}_q$) [40].

To perform the series of hypothesis tests, 50 square patches containing 400 pixels were constructed for each class (Figure 3a). The patches were constructed by plotting a grid of 200x200m over the BNP vector in QGIS and randomly selecting 50 cells within the classes' spatial extent. The patches' size was constrained by the Forest class, since its occurrence is found along streams and its maximum width was not greater than 200 meters in the terrain. The selected cells were used as masks in a Python script that reads the vegetation indices' rasters, calculates the patch distribution parameters and saves the samples in .CSV files for each date on the temporal dataset.

In the literature, there are examples of stochastic distances assessment employed for speckle noise reduction in SAR images by modeling the targets as complex Wishart distributions [43], Gamma distributions [44] or \mathcal{G}^0 distributions [40]. In this study, we assessed several distributions and the log-normal distribution was found to be the most suitable model for characterizing empirical distributions of all vegetation indices' sample patches in the spatial domain for both seasons.

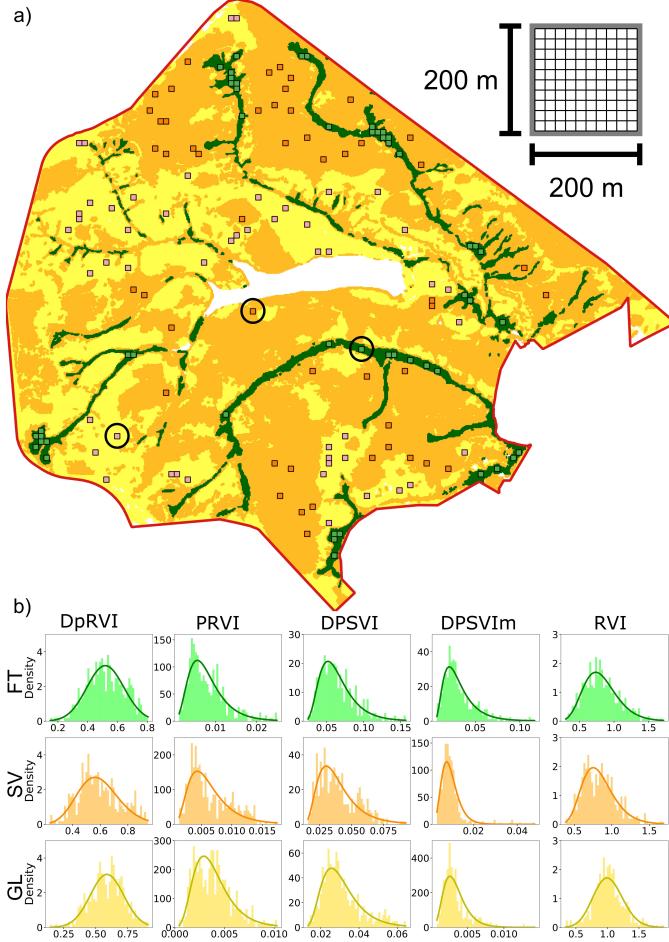


Fig. 3. a) Spatialization of classes' sample patches used in the hypothesis tests. The sketch on the upper right corner is an example of a square sample patch. b) Empirical (bars) and fitted with the log-normal model (solid lines) spatial patch distributions of each vegetation index, respective to the patches highlighted in the map by black circles.

Examples of sample patches distribution modeled by the log-normal model of each SAR vegetation index are given in Figure 3b). Hence, to perform the hypothesis tests, the sample patches distribution was parameterized in terms of the mean (μ) and the standard deviation (σ) and, thus represented by a parameter vector ($\hat{\theta} = \mu, \sigma$).

The hypothesis test was performed for each vegetation index separately, comparing the patch distributions of different classes in a step-wise approach implemented in a Python script. The script algorithm is given as follows:

- 1) Select the log-normal parameter vectors of two different patches from two different classes ($\hat{\theta}_p = \mu_p, \sigma_p$ and $\hat{\theta}_q = \mu_q, \sigma_q$).

- 2) Calculate the Kullback-Leibler distance between parameter vectors (the proof is given in Appendix B):

$$d_{LN}(\hat{\theta}_p|\hat{\theta}_q) = \frac{\sigma_p^2(\mu_p - \mu_q)^2 + \sigma_q^2(\mu_q - \mu_p)^2 + (\sigma_p^2 - \sigma_q^2)^2}{4\sigma_p^2\sigma_q^2} \quad (12)$$

- 3) Calculate the test statistic:

$$s = \frac{2mnv}{m+n} d_{LN}(\hat{\theta}_p|\hat{\theta}_q) \quad (13)$$

where m, n are the sample size of distributions p and q , respectively. v is a constant (1 for Kullback-Leibler distances) [40].

4) Reject the null hypothesis if $Pr(\chi_M^2 > s) \leq \eta$, where M is the number of degrees of freedom of the chi square distribution, which is equal to the number of parameters of the target distributions. Since the distributions were parameterized in terms of mean and standard deviation, $M = 2$. η is the significance level of the tests, which was 0.05 in this study.

In the hypothesis tests, all possible pairs of patches of different classes were compared, totaling 7500 hypothesis tests per index and date. The null hypothesis rejection rates were calculated as the ratio between the H0 rejected tests and the total realized tests, and adopted as an indicator of the separability between the patch distributions. The rejection rates for each date were then plotted in temporal profiles for each vegetation index and pairs of classes.

III. RESULTS AND DISCUSSION

In this section, the potential of five SAR-C vegetation indices to describe seasonal dynamics of three vegetation classes in BNP was investigated. The results and discussion are organized as follows: Temporal profile analysis of DpRVI, RVI, PRVI, DPSVI and DPSVIm, respectively; Hypothesis tests over Kullback-Leibler distances.

A. DpRVI temporal profiles

The DpRVI temporal profiles for each class are given in Figure 4a). Overall, all classes showed a temporal development in approximately bell-shaped curves following a seasonal pattern. All classes' medians increased in the wet seasons within an uptrend, typically reaching their highest values around October-November. The index medians then began to decline within a downward trend that regularly ended in the middle of the dry season, around May-June, where the lowest values of DpRVI were recorded. Within the seasonal pattern, the median curves were farther from each other in the wet seasons, returning to almost the same values by the end of the dry seasons.

The classes' DpRVI curves suggests an inversely proportional response regarding the biomass level. Despite the similar shaped curves, the classes presented different behaviors regarding the index seasonal variations. The Forest class medians presented an almost constant behavior compared to the other classes, varying between 0.52-0.59 with an average of 0.55 ± 0.017 (mean \pm standard deviation), the lowest observed values and variation amplitudes in the time series. The Savanna class presented a similar behavior to the Forest's, but with more pronounced variation amplitudes in an intermediate range of median values, concentrated between 0.053-0.063 with an average of 0.57 ± 0.020 . The Grassland class presented the highest median values and variation amplitudes in the time series, varying between 0.54-0.66 with an average of 0.59 ± 0.029 .

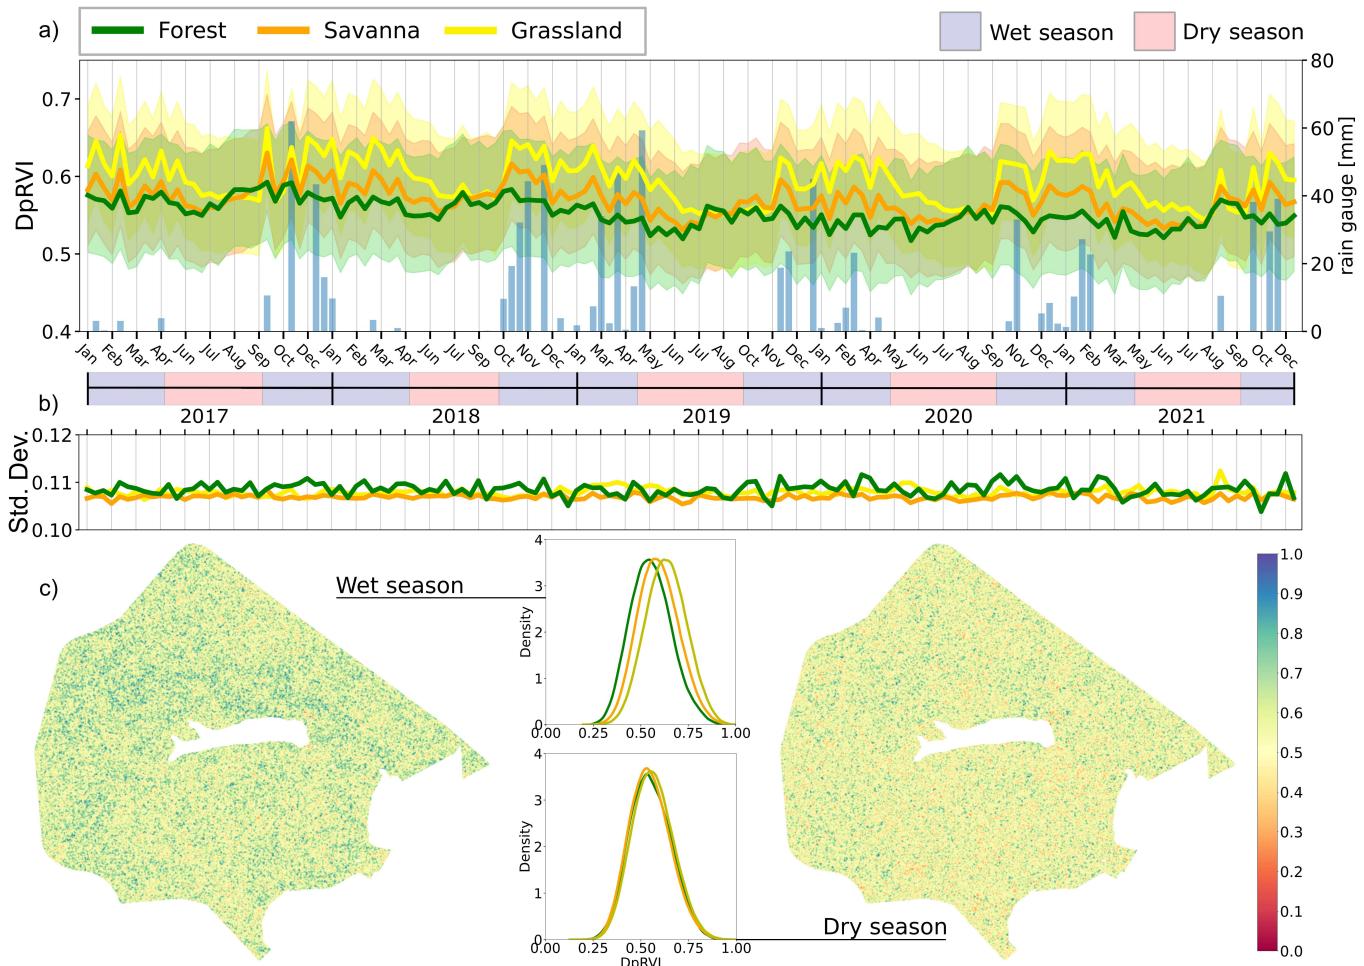


Fig. 4. a) DpRVI temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars; b) DpRVI standard deviation temporal profiles; c) Study site DpRVI maps and class distributions in the wet season (22/12/2020) and dry season (14/07/2021).

The classes IQR were similar along the time series, showing a high overlap between the classes' spatial distributions, despite the influence of seasonality. The IQR polygons also showed slight variations over time, an observation reinforced by the standard deviation profiles (Figure 4b). The classes' standard deviation presented slight fluctuations around 0.11, but without a clear seasonal pattern. The observed levels of spatial variance in DpRVI values might be caused by the structural heterogeneity of the classes' vegetation [22]. Hence, both IQR and standard deviation temporal behavior demonstrate that the seasonality influence only causes a shift in the classes' spatial distributions of DpRVI, not affecting its spread significantly over time.

The DpRVI profiles showed sensitivity to precipitation in the study site. In all classes' curves, the wet seasons presented more pronounced oscillations in the index median values than the dry season, where the curves were more stable. The oscillations were mainly linked to precipitation, observed as peaks in the curves. In rainy dates, the precipitation led to an increase in index values in all classes, but the response was different for each class, respective to biomass level and influence of soil moisture in the total scattered signal. In this context, the lower the biomass level, the higher the amplitude

of the peaks. However, not all precipitation events led to an index increase, but maintained the index at higher levels.

To exemplify the results spatially, DpRVI maps and its respective classes' spatial distributions were illustrated in Figure 4c). In both seasons, the maps presented predominantly DpRVI values around 0.5-0.6 (yellow) for all classes. The spatial distributions encompassing all pixels of the classes showed similar shapes in both examples, where the main difference was the distribution overlap. In the wet season example, the classes' distributions were shifted from each other, whereas a high overlap is still observed. In the dry season example, all classes' distributions look almost the same. As a consequence of the high overlap between classes' spatial distributions, both wet and dry season maps presented a similar fuzzy aspect, where the classes' spatial boundaries were hard to recognize visually. Similar aspect maps with lack of recognizable spatial geometries are also reported by [45] over wheat crops around the city of Varanasi, India.

In general, the results of this study contrast with the results reported by [22], possibly due to differences in phenological dynamics of agricultural crops and Cerrado physiognomies. The theoretical structure of DpRVI is based on the contrast of signal polarization between the bare soil and the vegetation

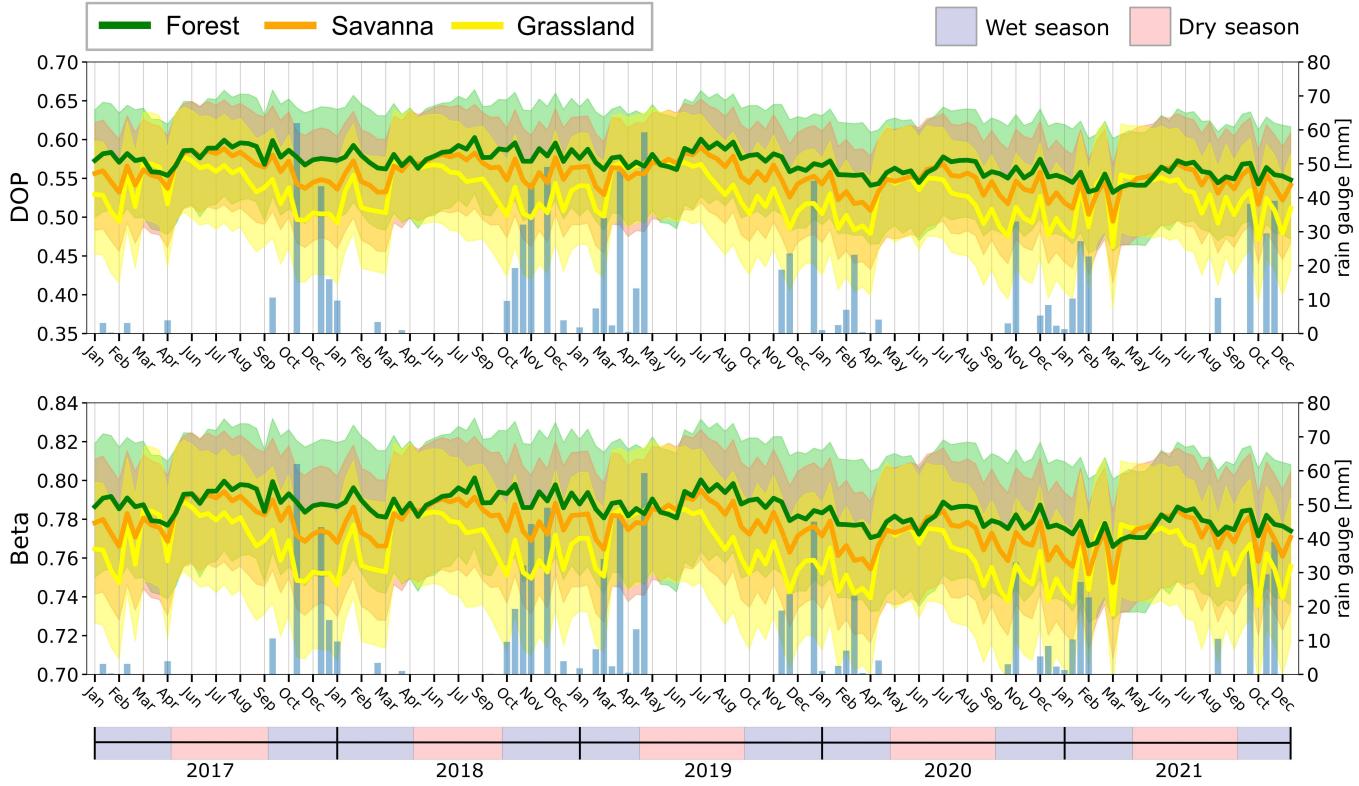


Fig. 5. DOP and Beta temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars.

backscattering in different crop phenological stages, which develops in few months from sow to harvest. In [22], the DpRVI values increased as a function of a higher degree of randomness in scattering with the advance of the crops' phenological stages. The increase in the scattering randomness was mainly driven by structural changes in plants in a context where the vegetation canopy was more complex and the signal was more depolarized as the plants grew. In this study, all classes presented a stable and cyclic seasonal behavior, where the contrast between classes were mainly driven by seasonality effects over the vegetation structure (up/down trends) and dielectric properties (peaks).

As the DOP and Beta profiles (Figure 5) indicate, the classes' vegetation presented similar levels of canopy complexity along the time series, even considering seasonality effects. The DOP curves indicate that the higher biomass level classes had higher medians and lower variation amplitudes. However, all classes cover almost the same range of values, concentrated between 0.38-0.66 along the time series. The Beta curves presented the same temporal behavior, directly proportional to the biomass level, where the classes showed a high overlap between its spatial distributions over time.

A decreasing trend in DOP and Beta was also observed by [22], which resulted in the increasing of DpRVI as the phenological stages of the studied crops advanced. In this study, as indicated in Figure 5, the DOP curves were directly proportional to biomass levels, demonstrating that with the decrease of the biomass level, more depolarization occurred. With the increase in vegetation components and water content

in the wet seasons, the variations in DpRVI values among the classes were apparent. However, all classes' medians remained below 0.6 over the seasons, indicating that even with seasonality effects, the DOP only reached medium values. A similar behavior was observed for the classes' Beta median curves, which remained above 0.7 over the seasons, indicating a predominance of a single dominant scattering mechanism over all classes' spatial extent. Within this context, the classes seem to produce similar spatial distributions of DpRVI by presenting similar levels of DOP and scattering mechanisms dominance across seasons. A possible explanation for this scenario is that the surface roughness and canopy leaf layer contribute more to scattering at a higher mean incidence angle (such as 38,14° in this study), which reduces the effect of volume contribution in the backscattered signal [22].

The classes' temporal behavior of DOP and Beta might be an indicator of the saturation of C-band signal. The dense biomass levels such as in Forest class blocks C-band signal interactions with the underlying soil, and the consequent signal saturation leads to similar levels of DOP in both seasons. The effect of signal saturation is observed through the narrow seasonal variations in the Forest curves of DOP and Beta, which can also be a result of the evergreen condition of this vegetation class. The saturation effect might be attenuated as biomass level decreases, leading to more pronounced variations in DOP and Beta for Savanna and Grassland, likely due to the increasing influence of the underlying soil on the classes' backscattering response.

Those assumptions are reinforced by the visual difference

between DpRVI maps calculated using ALOS/PALSAR-2 data (L-band) and Sentinel-1 (C-band) in [45]. The L-band map presented a less fuzzy aspect and a wider range of values than C-band map, with some recognizable geometric spatial patterns of different crops. Moreover, statistically, the L-band DpRVI outperformed the C-band DpRVI in a first order microwave scattering algorithm to simulate the SAR backscattering response of the studied targets. Those observations point to a hypothesis that L-band DpRVI may effectively describe the different vegetation classes in BNP. Future SAR missions like NISAR and BIOMASS would permit assessing this hypothesis.

Summarizing the findings, as indicated by the DpRVI curves, maps, and spatial distributions, the seasonality indeed affects the classes' DpRVI response. The different responses regarding biomass levels and soil scattering influence offers a certain level of separability between classes, which is enhanced in the wet seasons, especially on rainy dates. Those differences are difficult to recognize, mainly for visual interpretation of the maps, due to the stability of the classes' temporal behavior. However, such stable seasonal behavior can be a suitable parameter for monitoring possible disturbances in the classes' vegetation structure.

Monitoring strategies such as those described in [46] for the Amazonia biome may use DpRVI as a proxy of the temporal stability of the Cerrado physiognomies. In this context, any perturbation of the known temporal behavior within previously mapped classes spatial extents can be taken as an alert of disturbances like low-cut deforestation in preserved Cerrado regions.

B. RVI temporal profiles

The RVI temporal profiles are shown on Figure 6a). The classes' temporal development occurred within a seasonal pattern, increasing in the wet seasons and decreasing in the dry seasons. In the wet seasons, the classes' medians increased within an uptrend in the first months of the season, reaching a plateau in the middle of the season. The index then began to decline in a downward trend, typically reaching its lowest median values in the middle of the dry season, around July-August. Inside the seasonal pattern, the median curves were farther from each other in the wet seasons, reaching almost the same values in the end of the dry seasons, a behavior similar to DpRVI.

The classes' bell-shaped curves suggest an inversely proportional response regarding the biomass level, where each class presented different variations over time. The Forest class had an almost constant behavior when compared to the other classes, varying between 0.75-0.90 with an average of 0.81 ± 0.033 (mean \pm standard deviation). The Savanna class presented a curve shape similar to Forest, but more pronounced variation amplitudes, especially on wet seasons. The Savanna class medians were concentrated between 0.77-0.98 with an average of 0.85 ± 0.042 , configuring a intermediate range of values. The Grassland class presented the highest median values and variation amplitudes in the time series, especially on the wet seasons. The class medians were concentrated between 0.79-1.06, with an average of 0.90 ± 0.064 .

The classes' IQR were similar along the time series, presenting a high overlap between its spatial distributions over time. The IQR polygons around the medians showed seasonal variations, which is reinforced by the classes' standard deviation curves (Figure 6b). The standard deviation curves presented a temporal behavior similar with the classes' medians with bell-shaped curves. The variation amplitudes were observed as inversely proportional to the biomass level, suggesting that the index spatial variance decreases with the increase of biomass. Hence, both IQR and standard temporal behavior indicate that seasonality affects the shift and the spread of the RVI spatial distributions.

The RVI median curves showed sensitivity to precipitation. In all profiles, the wet seasons presented more pronounced oscillations in the index median values than the dry seasons, where the curves were smoother. The wet seasons' oscillations were mainly linked to precipitation, observed as peaks in all classes' curves. However, not all precipitation events led to an increase of the index, but maintained its higher levels, similar to the DpRVI curves. In rainy dates, precipitation led to an increase in the index values in all classes, but the response was different regarding the biomass level and the influence of the soil in the total scattered signal. In this context, the lower the biomass level, the higher the amplitude of the peaks.

To exemplify seasonal influence on RVI in the spatial domain, maps and its respective classes' spatial distributions were constructed for different dates in the wet and dry seasons (Figure 6c). In both seasons, the maps presented predominantly RVI values around 0.7-1.2 for all classes. The classes spatial distributions showed similar shapes in both examples, where the main difference was the distribution overlap. On the wet season example, the classes' distributions were shifted from each other but with a high overlap. In the dry season example, all classes' distributions look almost the same. As a consequence of the persistent high overlap between the classes' spatial distributions, both wet and dry seasons maps presented a similar fuzzy aspect, where the classes' spatial boundaries were hard to recognize visually. The C-band RVI map over wheat crops around the city of Varanasi, India, presented by [45] had a similar fuzzy aspect without recognizable spatial geometries.

Since the RVI formulation is a measure of scattering randomness in the radar signal, its behavior is similar to DpRVI. In practice, RVI can be also considered as a SAR parameter that expresses the variation rate of the radar signal over the classes. Considering the fact that the vegetation classes in BNP maintain high volumes of scatterers over time, the classes' scattering randomness may be mainly driven by seasonal influence in the vegetation phenologies.

The range of values of RVI over the BNP classes was similar to the range of rapeseed plots [47] in France, wheat [48] and, mustard fields [49] in North India. Since RVI is an unbounded index, the range similarity between vegetations of different biomass levels reinforces the insight that RVI is not directly related with biomass level. The relationship is indirect, by measuring the canopy complexity which is often a consequence of biomass increase. However, despite the range similarity, the main difference between the Cerrado physiog-

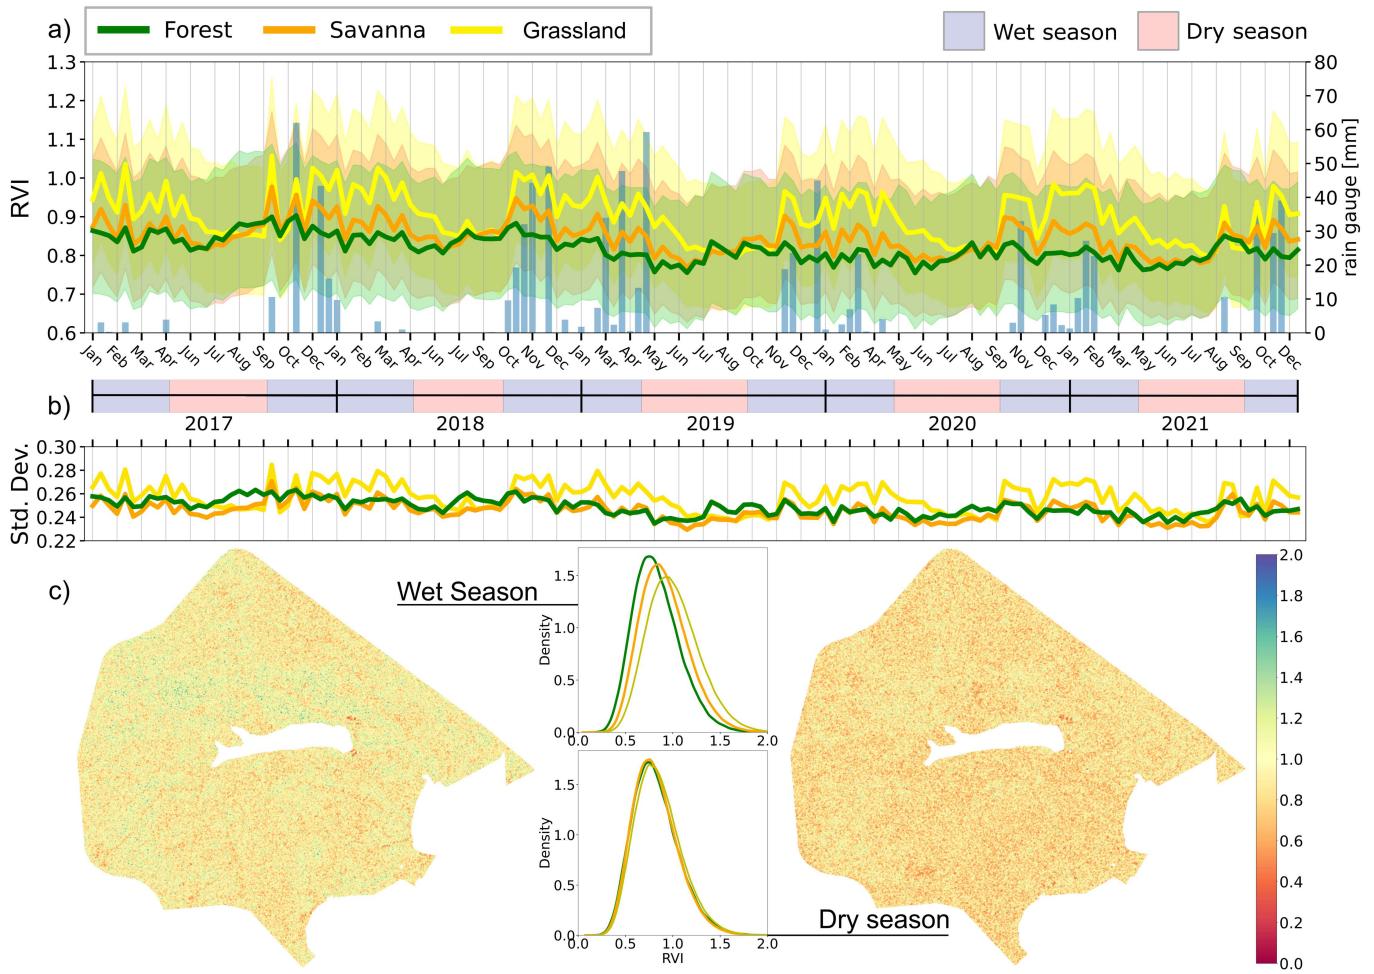


Fig. 6. RVI temporal profiles of spatial median, interquartile range and standard deviation. The boxplots summarizes the median values in the temporal domain. (*) indicates precipitation events in the study site. Rainfall seasonality is indicated in background colors.

nomic and crops like rapeseed and wheat is the temporal development of RVI, which is related to plants' phenologies. The phenologies of the vegetation classes' plants in this study are linked with the seasonality in BNP, as described in Figure 6. The plots of rapeseed, wheat, and mustard had a typical crop behavior, showing a continuous increase of RVI as plants grow until their harvest.

An example of a study that took advantage of the RVI characteristics was [50]. The authors used RVI as a SAR descriptor for mapping burned areas in forested regions of Portugal and Italy. The study findings point out that RVI was well suited to define areas affected by fire occurrence. Forest structure loss and soil moisture changes after a forest fire lead to less reflection on the C-band signal on burned areas [50]. In this context, the loss of canopy complexity creates a contrast between burned areas (low backscatter) and vegetated areas, due to differences in cross-polarized backscattering. Hence, the RVI maps on [50] presented the burned regions as darker areas.

The findings on RVI temporal behavior indicates that seasonality indeed affects the response of the index for each class. The different responses regarding canopy complexity (indirectly linked with biomass levels) and soil scattering

influence offers a low level of separability between the classes. The separability between classes was enhanced in the wet seasons, specially on rainy dates. However, the different classes' responses are difficult to recognize, mainly for visual interpretation of the maps.

In practice, the main source of separability offered by RVI is the rate of variation in the radar signal for each class. The different rate of variation can be a suitable parameter to measure the stability of the canopy complexity, thus an indirect measure of vegetation stability over time. In this context, disturbances of the known baseline temporal behavior of preserved Cerrado regions, caused by low-cut deforestation or forest fires, can be considered as an alert.

C. PRVI temporal profiles

Overall, the classes' PRVI profiles show a temporal behavior following a typical seasonal pattern with approximately bell-shaped curves over the seasons (Figure 7a). All classes' medians increased in the wet season within an uptrend, reaching the highest values around October-November. The classes' curves decreased in the dry season on a downward trend that regularly ended amid the dry seasons (around July-September), where the index's lowest values were often observed. Furthermore,

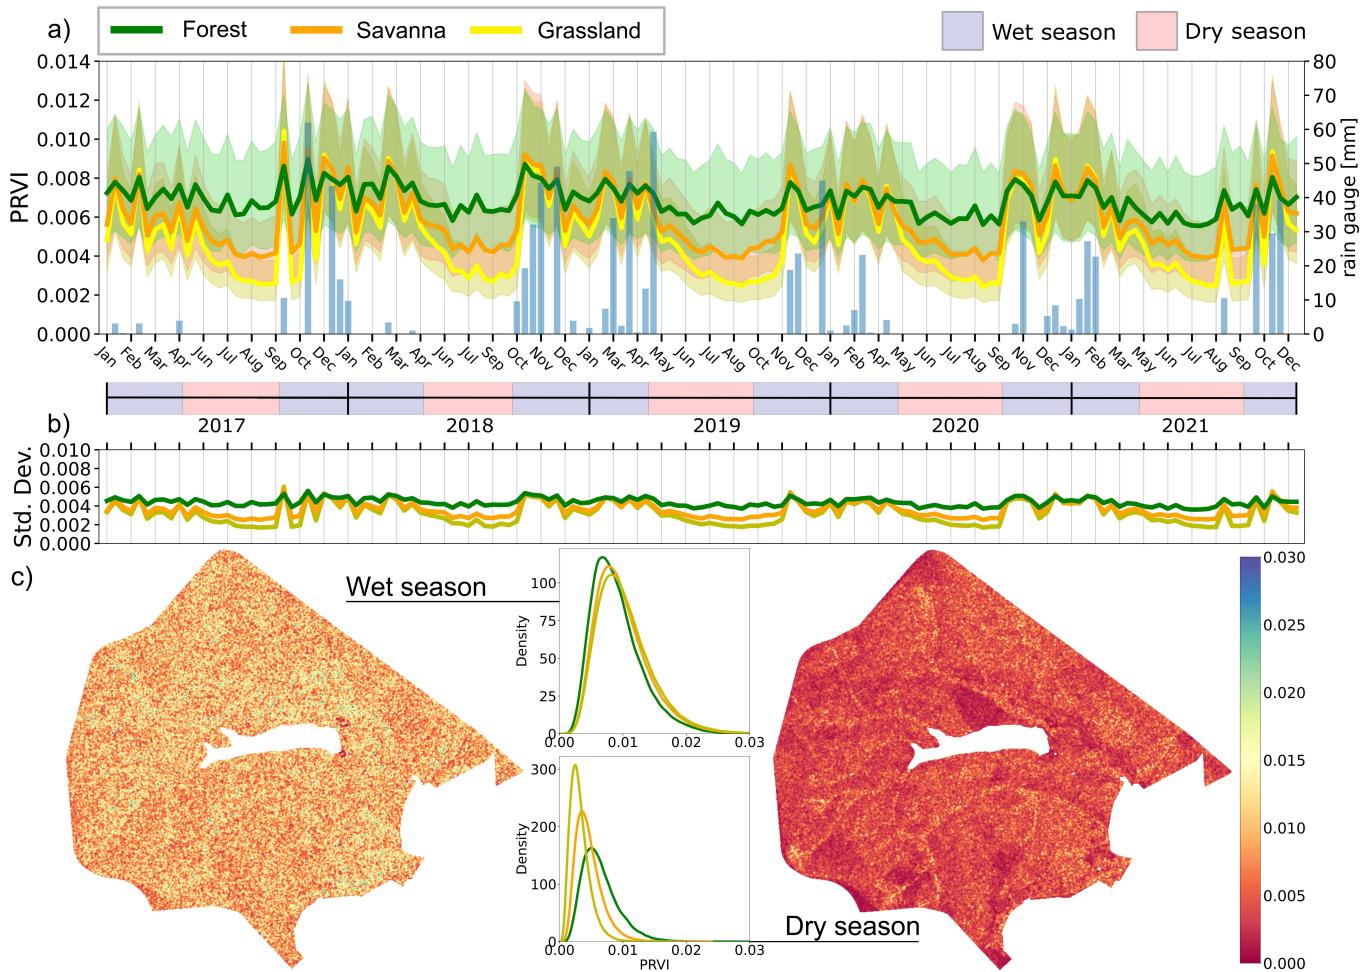


Fig. 7. a) PRVI temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars; b) PRVI standard deviation temporal profiles; c) PRVI maps and classes distributions in the wet season (22/12/2020) and dry season (14/07/2021).

within the seasonal pattern, the classes' medians' curves were farther from each other in the dry seasons, reaching almost the same values in the wet seasons, especially on rainy dates.

Originally, the PRVI was assessed with L-band SAR data. Positive correlations between PRVI (dB) values and estimated above ground biomass were found in Shrubland regions in Israel [18]. The L-band data was used in the study since the C-band backscatter parameters of Sentinel-1 showed lesser correlation with AGB, attributed to its shallower penetration depth compared with L-band [18]. [51] found positive correlations ($R^2 = 0.56$) between PRVI values (in dB) and above-ground biomass values (in Mg/ha) in different plots of mangrove forests in the Mundra region, within the Karchchh District, India.

In this study, the classes' PRVI curves behavior denotes a directly proportional response regarding the biomass level, not being directly assessed for AGB values. However, the amplitude of the classes' median fluctuations were higher with the lower biomass levels. The Forest medians were almost constant when compared with the other classes, varying between 0.0055-0.0090, with an average of 0.0068 ± 0.0008 (mean \pm standard deviation). The Savanna medians curve presented a behavior similar to Forest, but more pronounced

fluctuation amplitudes in a intermediate range of values, which were concentrated between 0.0038-0.010 with an average of 0.0059 ± 0.0016 . The Grassland medians presented the lowest median values but the highest variation amplitudes over time, fluctuating between 0.0024-0.010 with an average of 0.0051 ± 0.0021 .

Notably, the precipitation events affected the PRVI values over time. In the dry seasons, the PRVI values were directly proportional to the biomass level; i.e., the higher the biomass level, the higher the index values. In contrast, the wet season peak values reached very similar values for all classes. In all profiles, the wet seasons were characterized by more pronounced oscillations in the index medians than the dry season, where the curves were more well-behaved.

The index peak was reached several times in the wet seasons, mostly on rainy dates, producing pronounced oscillations within the classes' bell-shaped curves. The amplitude of the peaks was inversely proportional to the biomass level, i.e. the lower the biomass level, the higher amplitude of the peak. The precipitation led to an abrupt increase in the index values to very similar values in all profiles. In that case, the main difference between the classes was the amplitude of the peak.

Another influence of seasonality in the classes' curves was

in seasonal trends, which was possibly linked with vegetation structure changes. Within the wet seasons, the median values in non-rainy dates were the indicator of an uptrend, showing increases over time beyond the peaks on rainy dates. The increase in PRVI medians were possibly due to the increase in vegetation components, according to the vegetation phenology of each class, as a consequence of the abundance of water in the BNP soil. In this context, the increase in the vegetation components probably makes the vegetation structures more random, enhancing their capacity to depolarize the radar signal.

This observation is reinforced by the DOP curves in Figure 5, which shows a decreasing trend within the wet seasons, beyond the influence of the precipitation. Furthermore, with the increase of the PRVI medians, the amplitude of the peaks decreased, especially for the Grassland curve. Those results suggest that the precipitation influence on the PRVI values is constrained by vegetation structure. On the other hand, in the dry seasons, the downtrends can be related with the decrease of vegetation components. Due to scarcity of water in the soil, most of the vegetation in Savanna and Grassland experiences some loss of components like leaves and stems, establishing a dry biomass [29].

The classes' IQR were significantly different from each other along the time series. The IQR polygons around the classes' median curves showed variations over time, indicating that the distributions were more spread out in the wet seasons than in the dry seasons. Those observations are reinforced by the classes' standard deviation curves in Figure 7b). In the spatial domain, the spread of the classes were directly proportional to the biomass level, suggesting that PRVI response in lower biomass levels was more homogeneous.

In the temporal domain, the spread of the classes followed a seasonal pattern, similar to the classes' median curves fluctuations. The fluctuations of the curves were inversely proportional to the biomass level, where the Grassland curve showed the most pronounced seasonal variations, followed by Savanna and Forest, respectively. Those observations indicate that the rainfall seasonality affects both the shift and the spread of PRVI distributions over time, where wet seasons insert more uncertainty in PRVI than the dry seasons.

Within the seasonal pattern, the spread of the classes' spatial distributions increased in the wet seasons, frequently reaching similar values in the rainy dates. In those dates, it is possible to observe that the IQR values for all classes often covered almost the same range of values, with similar median values. In practice, those observations denote that the distributions were almost equal in the spatial domain. The recurrence of these observations within the wet seasons suggests that the precipitation equalizes the PRVI response, shifting and spreading the distributions to approximately the same range of values. The amplitude of the shifts was different for each class over time, but the median values did not surpass 0.10 along the time series. This context suggests that the precipitation raises the PRVI medians to a saturation point, which was around 0.8-0.10. This phenomenon is here called index equalization.

To illustrate the seasonal differences in the spatial domain, PRVI maps and their respective classes' spatial distributions

were illustrated in Figure 7c). In the wet season example, the classes' spatial distributions were almost the same, with similar shapes covering almost the same range of values. The high overlap between the classes' spatial distributions resulted in a map with a fuzzy visual aspect, without clear recognizable spatial patterns of the classes. This is a result of the index equalization effect, that degrades the classes separability by shifting the classes' spatial distributions to almost same levels.

In contrast, the dry season example presented significant differences between the classes' spatial distributions, with some degree of overlap. The result was a map where the classes' spatial patterns are recognizable, where Forest is displayed in yellow, Savanna in orange and Grassland in red. The aspect of those maps contrasts with the C-band PRVI map in [45], which do not present clear spatial patterns of wheat crops.

The separability degree observed in the temporal profiles and the maps suggests that PRVI has the capacity to distinguish the classes by biomass level. However, given its temporal behavior, this separability is degraded in the wet seasons given the sensitivity of the index to precipitation. Its separability is enhanced in the dry seasons, but maintains a high overlap between the classes' spatial distributions over time.

Overall, the classes' PRVI temporal behavior showed a different behavior than the DpRVI profiles, which also use DOP. This might be a result of a possible higher influence of VH than the term (1-DOP) in PRVI results. As analyzed before, the classes' DOP were directly proportional to the biomass level. In this case, the term 1-DOP inverts the curve trends, indicating that more depolarization of the radar signal occurs with the decrease in the biomass levels of the classes. By multiplying (1-DOP) by VH, the classes' curves assumed the characteristic seasonal shape in BNP.

It seems that the use of σ_{vh} gives PRVI a sensitivity to biomass level and precipitation. This is likely the cause of its more pronounced fluctuations in the wet season. The oscillation of PRVI in the wet season might be due to the incorporation of σ_{vh} sensitiveness to the dielectric constant changes in the index formulation.

D. DPSVI temporal profiles

The spatio-temporal development of DPSVI profiles is displayed in Figure 8a). Overall, all classes' curves followed the seasonality trend patterns on the study site, where the index increased in the wet seasons and decreased in the dry seasons in clear bell-shaped curves. The wet seasons were characterized by uptrends in all classes, with pronounced oscillations in the rainy dates. The dry seasons were characterized by more well-behaved curves, where the lowest DPSVI median values were typically found.

Within the seasons pattern, the classes' median curves were farther from each other in the dry seasons, reaching almost the same values in the wet seasons, especially on rainy dates. [52] investigated the post-fire vegetation regrowth in Portugal and also observed DPSVI inter-seasonal variation patterns mainly driven by humidity conditions, especially caused by precipitation over the study site.

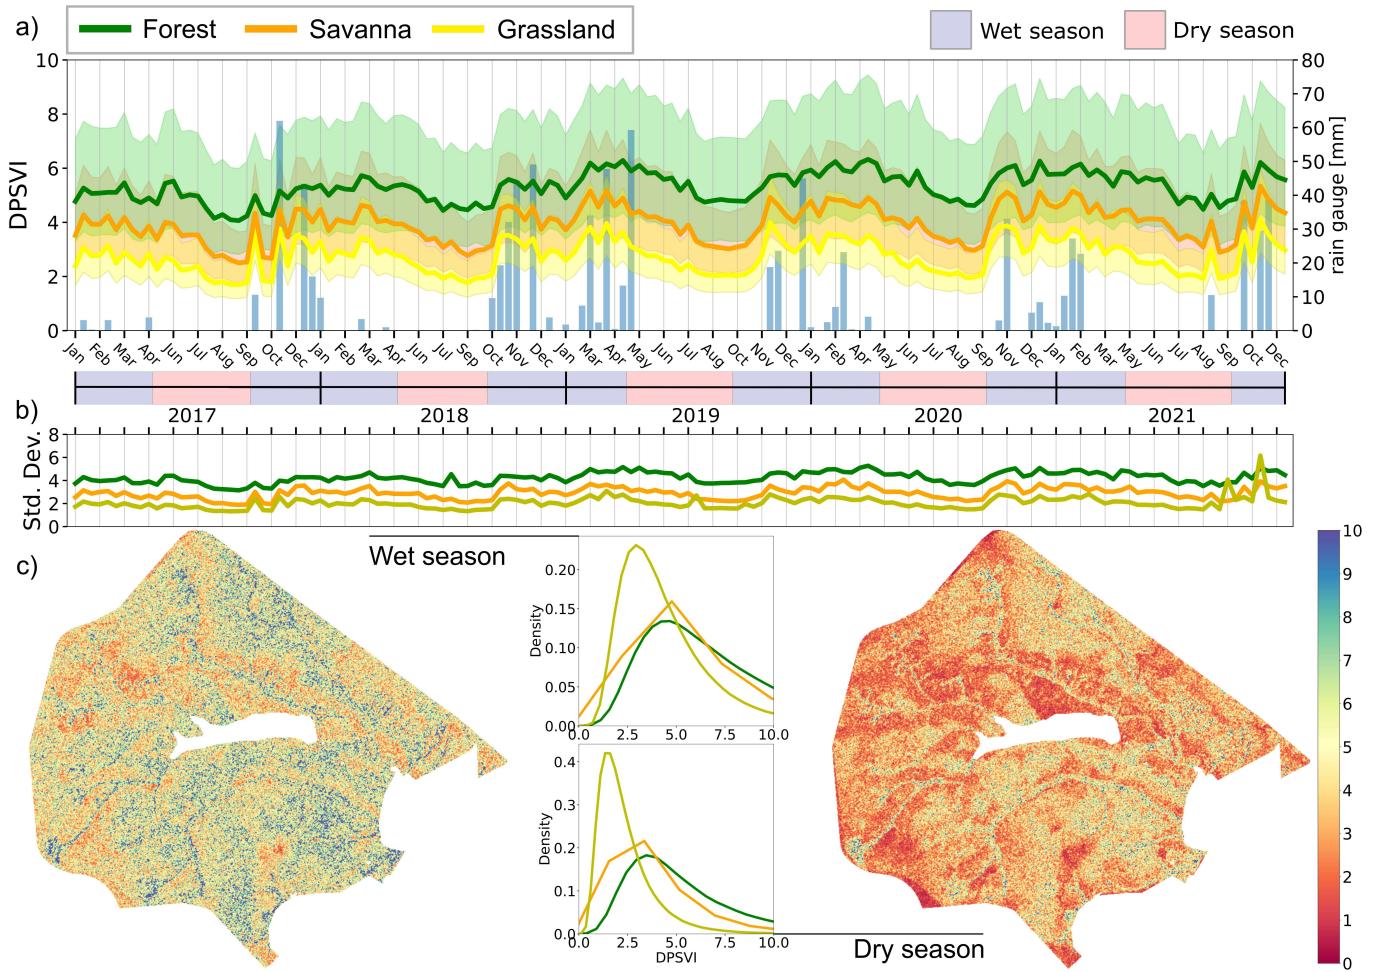


Fig. 8. a) DPSVI temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars; b) Standard deviation temporal profiles; c) Study site maps and classes distributions in the wet season (22/12/2020) and dry season (14/07/2021).

All classes' DPSVI median curves presented similar shapes, where its range of values were directly proportional to the biomass level. The Forest class varied within the seasonal pattern with the highest medians, varying between 4.06-6.33 with an average of 5.30 ± 0.54 (mean \pm standard deviation). The Savanna class varied within an intermediate range of medians, concentrated between 2.50-5.34 with an average of 3.96 ± 0.66 . The Grassland class presented the lowest median values, varying between 1.70-4.13, with an average of 2.76 ± 0.61 .

The amplitude of the variations increased with the decrease in the biomass level, i.e., the Grassland class presented the most pronounced variation amplitudes, followed by Savanna and Forest, respectively. These observations agree with the findings of [19], which found positive correlations between in situ AGB data and DPSVI in both wet and dry seasons. Furthermore, the observed range of values assumed by the vegetation classes in BNP are in consonance with the statement that DPSVI values higher than 1 are representative of healthy vegetation [19]. The stratified range of values above 1 and directly proportional to the biomass level is an evidence of the DPSVI capacity to map vegetation targets with different canopy complexities.

The DPSVI median curves also indicate the sensitivity

of the index to precipitation. In wet seasons, the peak of DPSVI was typically reached in rainy dates. However, not all peaks reached the same median value in those dates. The index equalization effect was only observed in the first two precipitations on the wet season of 2017-2018. In other rainy dates, the distances between the classes' medians seem to be almost symmetrical. Considering the precipitation intensities along the time series, it seems that this scenario is not directly correlated with the volume of precipitation, and the reasons for these observations remain unknown. In practice, the classes' temporal behavior suggests that DPSVI attenuates the index equalization effect, maintaining its distributions well separated despite the influence of seasonality on the study site.

On the time series, the classes' IQR (Figure 8a) and standard deviation curves (Figure 8b) suggest that the classes' distributions presented significant differences regarding the biomass level. The Forest class presented the highest IQR and standard deviation over the seasons, followed by Savanna and Grassland, respectively. This scenario suggests that the DPSVI of higher biomass levels carries more uncertainty than lower biomass levels in the spatial domain.

In the temporal domain, the IQR polygons around the medians presented slight variations, mainly following the shift

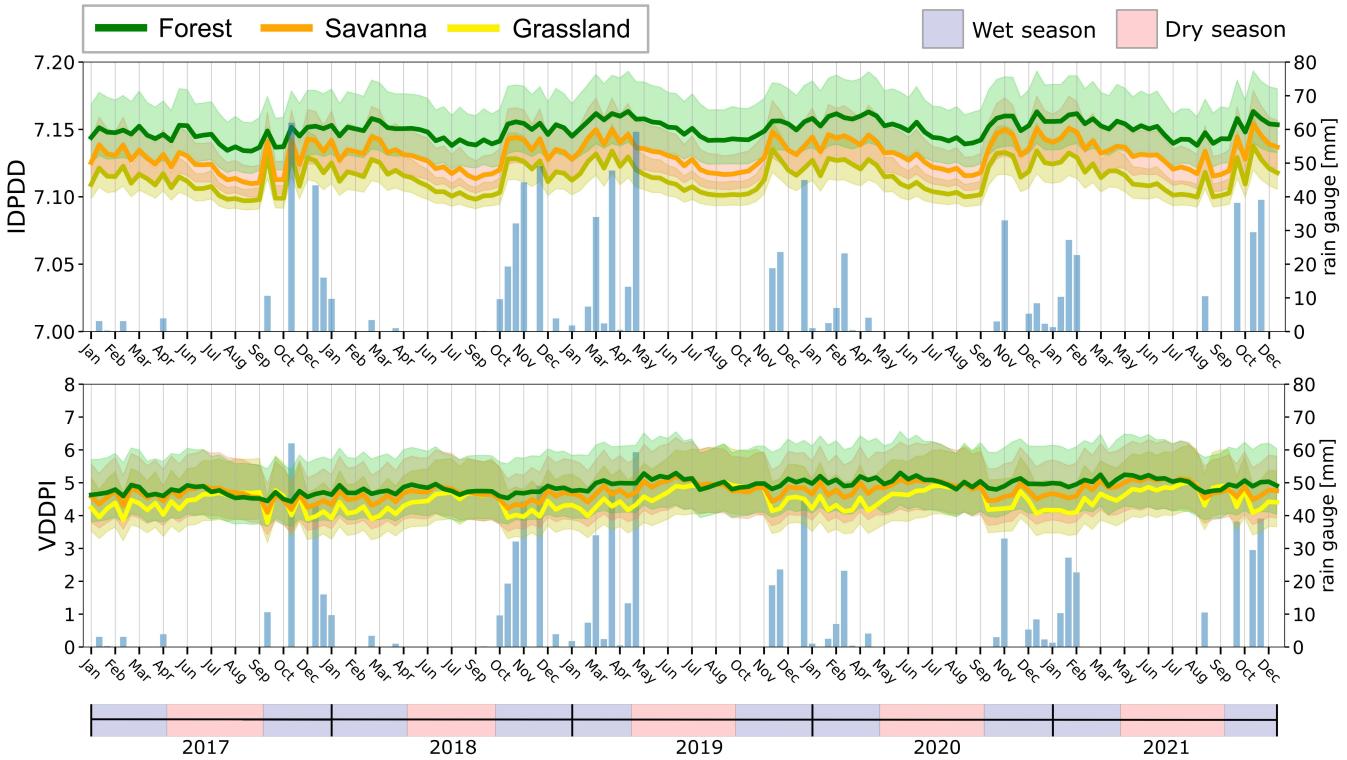


Fig. 9. a) DPSVI temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars; b) Standard deviation temporal profiles; c) Study site maps and classes distributions in the wet season (22/12/2020) and dry season (14/07/2021).

of the medians. The classes' standard deviations follow the seasonal pattern, but the amplitude of the variations was narrow. The almost constant temporal behavior of the classes' standard deviation curves evidences a slight difference in the distributions spread in wet and dry seasons. Those results suggest that seasonality affects mainly the shift of the distributions, whereas the spread was not significantly affected over time.

To illustrate the results spatially, DPSVI maps and its respective classes spatial distributions in both wet and dry seasons were constructed (Figure 8c). In the wet season example, it is possible to observe a high overlap between the spatial distribution of Forest and Savanna. Both classes showed higher values and the distribution overlap resulted in a difficult visual interpretation of these classes' spatial extents, which are displayed in violet-to-blue colors in the map. The visual appearance of Forest and Savanna in the wet season map seems to be saturated in the range of 0-10.

In the dry season example, the classes' distribution overlap decreased, enhancing the separability between classes. The result was a map with clear recognition of all classes' spatial patterns. Those observations are in consonance with the maps in [19], which differentiated sparse and dense vegetations in different classes.

In [19], the focus of the study was the assessment of DPSVI as a general vegetation descriptor, exploring its contrast with other targets such as water bodies and bare surfaces. The author found positive correlations between DPSVI and NDVI for both wet ($R^2 = 0.749$) and dry seasons ($R^2 = 0.726$),

demonstrating the reliability of the index regarding seasonality. In this study, the results indicate that DPSVI has a well-suited capacity to distinguish vegetation covers with distinct biomass levels in BNP, despite the influence of seasonality. The medians remained separate in almost all time series, with exceptions in some rainy dates.

Beyond the results of this study, recent researches validate the capacity of DPSVI for such analysis. [53] used DPSVI and its derivatives (IDPDD, DPDD, and VDDPI) to analyze the impacts of hail damage in plots of corn, wheat, and soybean crops in Argentina. The analysis of 100 pixels within the study site presented a homogeneous DPSVI pre-storm behavior and an increase in the variance after the storm, highlighting the sensitivity of the index to the backscatter changes caused by a hail storm in the studied plot. [50] investigated the use of DPSVI as a vegetation descriptor to map burned areas in forested regions of Portugal and Italy. The index showed sensitivity to the backscatter changes after forest fires, presenting well-defined areas of low backscatter in the burned regions. To understand how DPSVI was capable of such apparent separability between the vegetation classes, temporal profiles of IDPDD and VDDPI were also constructed (Figure 9).

IDPDD is a parameter that calculates euclidean distances within the image scatter plot, based on the concept of the Soil-Vegetation Edge [19]. Since the classes are representative of vegetations with different biomass levels, the curves were quite similar, with some degree of overlap between its spatial distributions over time. The degree of overlap between the classes'

curves (medians + IQR) might be related with the limitation of IDPDD due to the saturation of the C band over plants with more than a meter [19]. Moreover, the IDPDD curves were directly proportional to the biomass level, similarly with the DPSVI. These observations add the insight that IDPDD is an important source of biomass level separability within the DPSVI formulation.

The VDDPI curves show similar trends to DpRVI. This is a consistent observation, since the parameter is an estimation of the rate in which the surface depolarizes the transmitted radar signal [19]. In that case, by using VDDPI, the targets which do not change the polarization of the illuminated signal occupy the lower range and those which depolarize the signal occupy the higher range [19]. All three classes' curves were highly overlapped over time, denoting that the classes depolarize the radar signal in almost the same way, as suggested by the DOP and Beta curves on Figure 5. However, each class curves had a different rate of variation, evidencing the different influences of seasonality in its vegetation phenologies. Those observations validate that VDDPI is a parameter with sensitivity not to the biomass level, but to the rate of variation which the targets depolarize the radar signal.

The classes' DPSVI temporal profiles showed that the index is well suited to express the seasonal patterns of the BNP vegetation. The different responses regarding the biomass levels of the classes and soil scattering contribution offer a separability that can be used to map and model the AGB for Cerrado physiognomies. However, the index has an empirical characteristic by the incorporation of the parameter VV_{max} in IDPDD, which impair its implementation in a time series analysis and on complete automated monitoring strategies of the Cerrado physiognomies.

Those limitations on DPSVI also impair the comparability between different regions, since different areas in size and location probably will present different VV_{max} values. Moreover, the necessity of the scatter plots analysis inserts a source of human error in the model, since the establishment of the VV_{max} value is based on the analyst's judgment. Despite its limitations, the analysis of DPSVI can be useful to map disturbances such as low-cut deforestation, forest fires, and hazard damages in preserved Cerrado regions.

E. DPSVI_m temporal profiles

The temporal profiles of DPSVI_m for each class are given in (Figure 10a). The classes' profiles showed a temporal development that followed the characteristic seasonal pattern in BNP. All classes' medians developed in approximately bell-shaped curves, increasing in the wet seasons within an uptrend, typically reaching their highest values around February-March. The index medians then began to decline in a downward trend which typically ended in the middle of the dry seasons, around August-September. Within the seasonal pattern, the median curves were farther from each other in the dry seasons, reaching almost the same values on rainy dates in the wet seasons.

The DPSVI_m temporal profiles also showed that the response of the index throughout the seasons was directly

proportional to the biomass level of the classes. The Forest medians were the highest within the seasonal pattern, varying between 0.014-0.028, with an average of 0.021 ± 0.0035 (mean \pm standard deviation). The Savanna class occupied an intermediate range of values, where the medians were concentrated between 0.005-0.025, with an average of 0.013 ± 0.0050 . The Grassland medians presented the lowest values of DPSVI_m, but the highest variation amplitudes over time, fluctuating between 0.002-0.019, with an average of 0.008 ± 0.0044 .

These results are in consonance with the findings reported by [21], where DPSVI_m had a directly proportional response regarding the level of biomass of forested fragments in the Atlantic Forest biome in both seasons. In their work, forest formations and planted forests assumed higher values, followed by annual crops and pastures, respectively. The index was also capable of distinguishing plots with biomass around 50.0 Mg/ha from those with around 200.0 Mg/ha in near-flat areas. This is likely due to the enhanced sensitivity of DPDD on dense vegetated areas in comparison with IDPDD, and the Cross Ratio exponential behavior as a function of VDDPI in discriminating the increasing vegetation biomass levels [21].

The IQR was also found to be directly proportional to the biomass levels, which indicates that the spatial heterogeneity decreases with the decreasing of biomass (Figure 10a). The IQR polygons around the medians showed variations over time, indicating that the distributions were more spread out in the wet seasons than in the dry seasons. Those observations are reinforced by the classes' standard deviation curves given in Figure 10b). The classes' standard deviation curves showed an increase in wet seasons and a decrease in dry seasons, with different variation amplitudes, where the higher the biomass level, the lesser the variation amplitude. The variation amplitude difference between classes is likely due to the different level of attenuation of the co-pol channel (VV) between classes' vegetations.

The seasonal behavior of the medians, IQR, and standard deviation indicate that rainy seasons introduced more variance in the distributions as a reflection of the increase of the surface moisture on the targets and the increase of components in the vegetation structure. Hence, the effects of seasonality not only shifted the DPSVI_m distributions, but also changed their spread over time. This is especially highlighted in rainy dates, where some precipitation events led to sudden peaks of median and standard deviation. [21] also found that the variation of rainfall within the analyzed hydrological years introduced uncertainties in DPSVI_m, resulting in lower correlations with spectral indices in the wet seasons.

The DPSVI_m median curves on the classes' temporal profiles indicate the sensitivity of the index to precipitation in BNP. In the wet seasons, the peak of DPSVI_m was typically observed in rainy dates in all analyzed years. However, not all peaks reached almost the same value in those dates. The index equalization effect was observed in the first two precipitations on the 2017-2018 wet season. In other rainy dates, the distances between the classes' medians decreased, but did not reach the same levels. These observations suggest that the separability between the classes' DPSVI_m spatial distributions

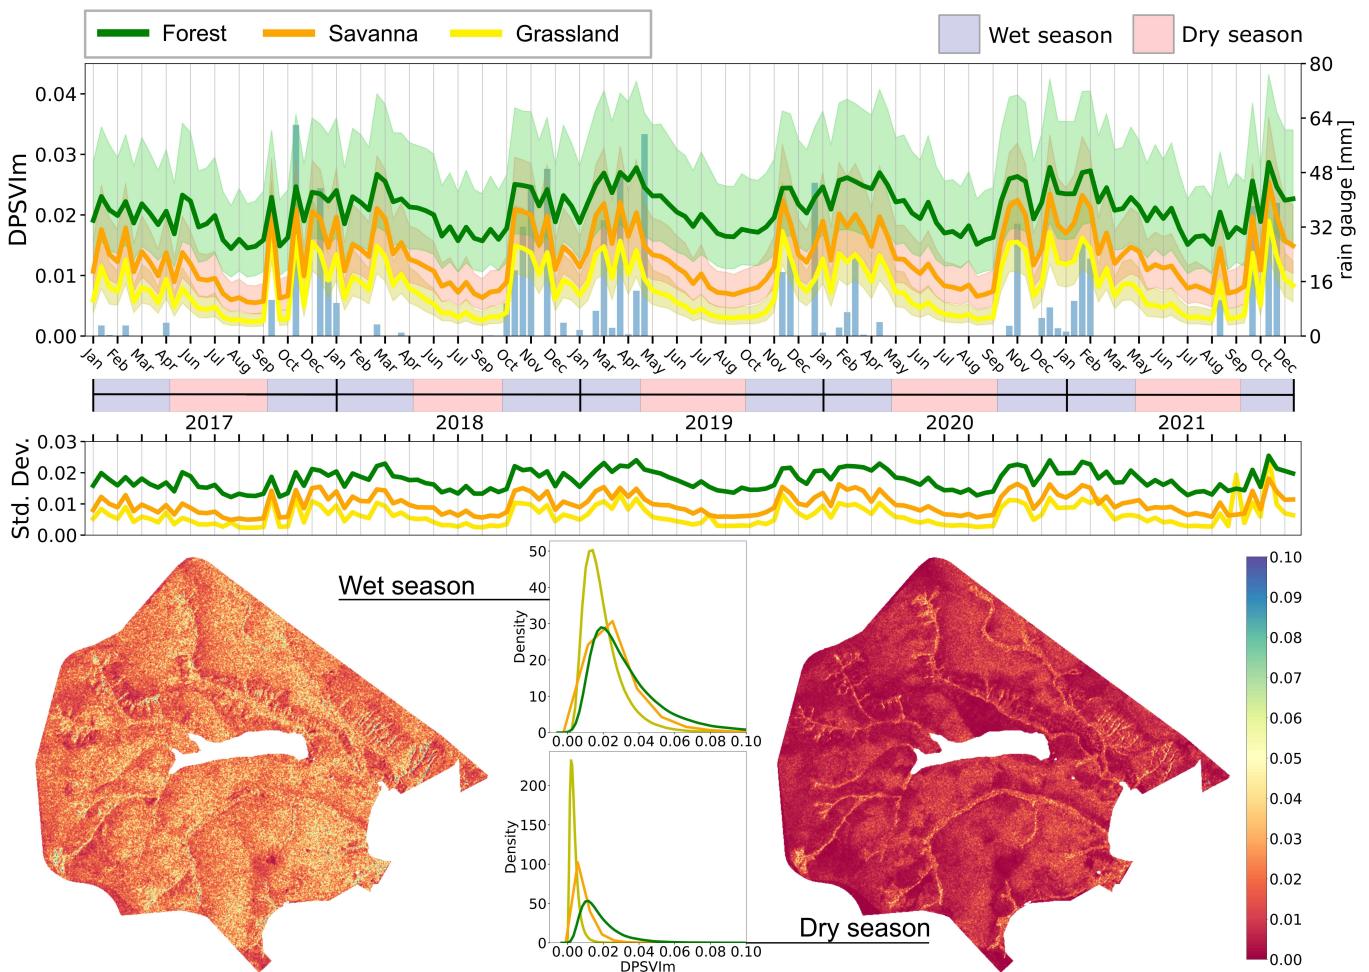


Fig. 10. a) DPSVIm temporal profiles of spatial median and interquartile range. The blue bars indicates the amount of precipitation over the study site. b) Standard deviation profiles. c) The boxplots summarizes the median values in the temporal domain; DPSVIm maps in the d) wet season (22/12/2020) and e) dry season (14/07/2021).

is degraded by influence of precipitation. Furthermore, as observed in DPSVI results, the precipitation intensities along the time series seem to not be directly correlated with the index equalization effect in DPSVIm results.

In fact, it seems that DPSVIm has the ability to attenuate the index equalization effect, maintaining a certain level of separability between the classes' spatial distributions despite the influence of seasonality, as DPSVI also does. In [21], the increase in the spread of distributions in the wet seasons resulted in lower correlations of DPSVIm with NDVI and EVI. The authors also found that the agreement between DPSVIm and the spectral indices tend to increase by the end of the dry seasons, observed as peaks of positive correlations in the analyzed hydrological years. Those observations were probably a side effect of the index equalization.

It is also noteworthy that a behavior often observed in all classes' profiles was the decrease in the medians and standard deviation in non-rainy dates after rainy dates. The decrease amplitude was different along the wet seasons, sometimes reaching DPSVIm values proportional to dry seasons. Those differences seem to shorten along the wet seasons, evidencing an uptrend beyond the peaks caused by precipitation. An

example of this is the 2017 dry-to-wet season transition. The uptrends presented a lag in the dry-to-wet season transition, due to the time needed to increase the structural components in the vegetation such as leaves, branches, and stems after the first precipitations in the wet seasons. Hence, it is possible to infer that the structural changes in vegetation are responsible for the seasonal DPSVIm trends, whereas the precipitation is responsible for the index peaks.

In terms of separability between classes, those results highlight the capacity of DPSVIm to distinguish the vegetation cover by biomass level. The reflections of the seasonality interference in DPSVIm classes' distributions are also noticeable in the maps and the respective classes' distributions (Figure 10c). In the wet season example, the classes' spatial distributions covered almost the same range of values. The overlap between the classes' spatial distributions resulted in a map with a fuzzy aspect, but with recognizable spatial patterns of the classes, especially Forest. Despite the index equalization effect on degrading the classes' separability, the wet season map evidenced the robustness of DPSVIm in maintaining some level of separability between classes.

In the dry season example, there were significant differences

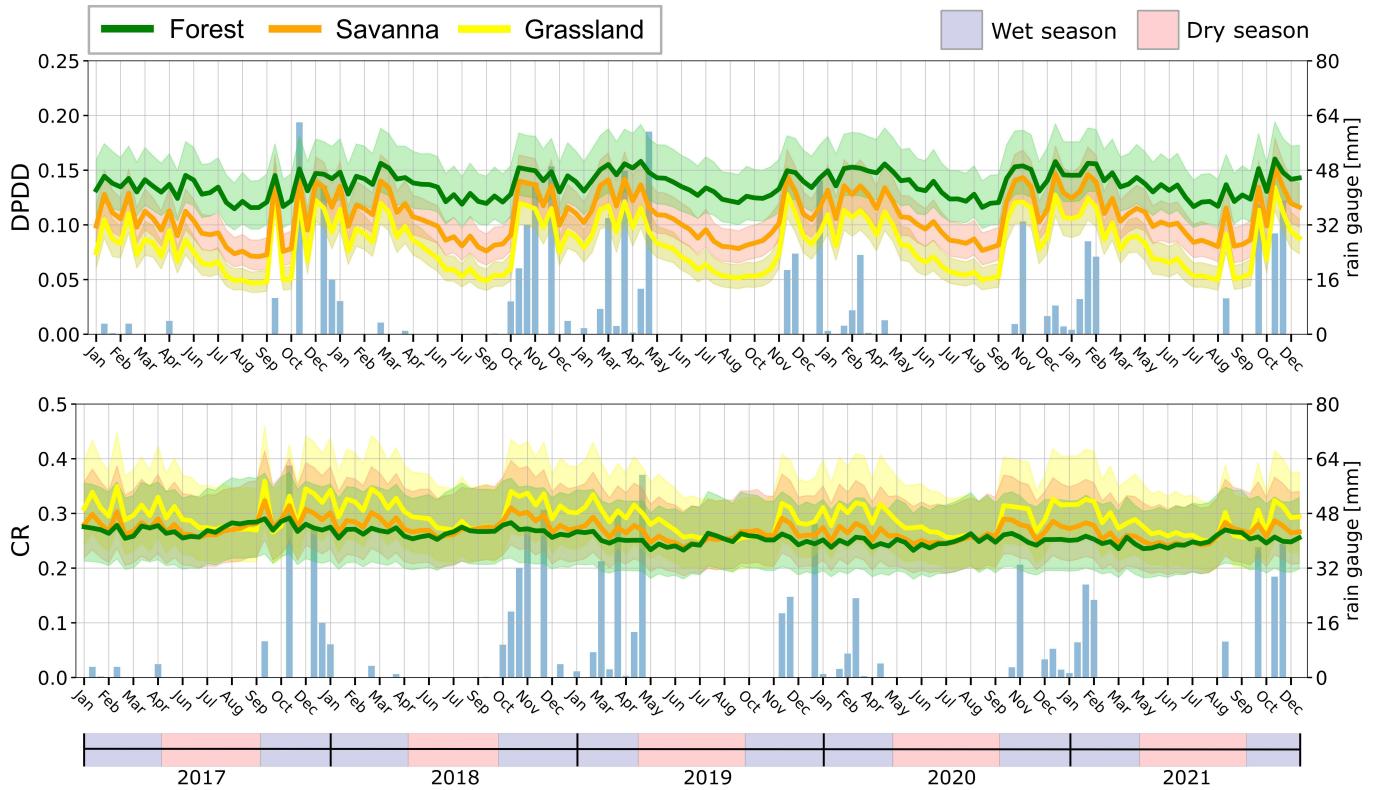


Fig. 11. DPDD and CR (VV/VH) temporal profiles of spatial median and interquartile range. The precipitation on each date is displayed in the background as blue bars.

between the classes' spatial distributions, where the density curves were shifted from each other, presenting also different spreads, as observed before. The visual aspect of the map allowed a clear recognition of the classes' spatial patterns, which evidences the capacity of DPSVIm to distinguish the vegetation cover by biomass level.

In general, the results of this study validate the DPSVIm capacity to distinguish vegetation covers with distinct biomass levels, despite the phenological differences between the Atlantic Forest vegetation and Cerrado physiognomies. The modifications proposed by [21] on DPSVI overcome its empirical characteristic, maintaining the separability between different biomass level vegetations in both wet and dry seasons. Regarding those modifications, to understand how DPSVIm is capable of such apparent separability between classes, temporal profiles of DPDD and CR (VV/VH) were constructed (Figure 11).

The DPDD temporal profiles presented a similar behavior to DPSVIm itself. The classes' curves' shapes and IQR polygons seasonal patterns were analogous to the variations of DPSVI and DPSVIm themselves. These observations additionally indicate that DPDD has a strong influence in the DPSVIm response. The classes' DPDD curves also presented strong similarities with the IDPDD curves (Figure 9). However, The DPDD curves' variations presented a higher amplitude than IDPDD. This result demonstrates that DPDD presented an enhanced capacity to distinguish different biomass levels in dense vegetated areas in comparison with IDPDD, as discussed

by [19].

The spatial variability in DPSVIm response is likely due to the influence of DPDD as a measure of a diagonal euclidean distance between the VV and VH response of the targets. In the Forest class, the backscatter is stronger in VH than in VV, and the diagonal distance is quite higher. The Savanna class, as a mixture of trees, shrubs, and grasses, present a more balanced response in VV and VH due to more soil influence in the regions with predominance of bushes, herbs and grasses. In this case, the variance is more likely to be controlled by the regions with more density of trees. The variance in the Grassland class was the lowest due to approximately equal diagonal distances as a consequence of the contribution of the soil scattering in the total backscattered signal in those regions. The predominance of grasses is expressed in more stronger VV backscattering than VH.

The CR temporal profiles presented a temporal development similar to DpRVI and RVI. The spatial distributions of CR showed a high overlap in the time series, where the main differences were regarding the medians, following the same seasonal patterns as DpRVI, RVI, and the polarimetric variables DOP and Beta.

[38] observed seasonal variations in CR over different stands of pine and oak in France, attributing the variations mainly to seasonal variations in VH, whereas VV remained nearly constant over time. In this study, it seems that CR actually works as a measure of the rate which the classes' SAR response changes as a function of the seasonality influence

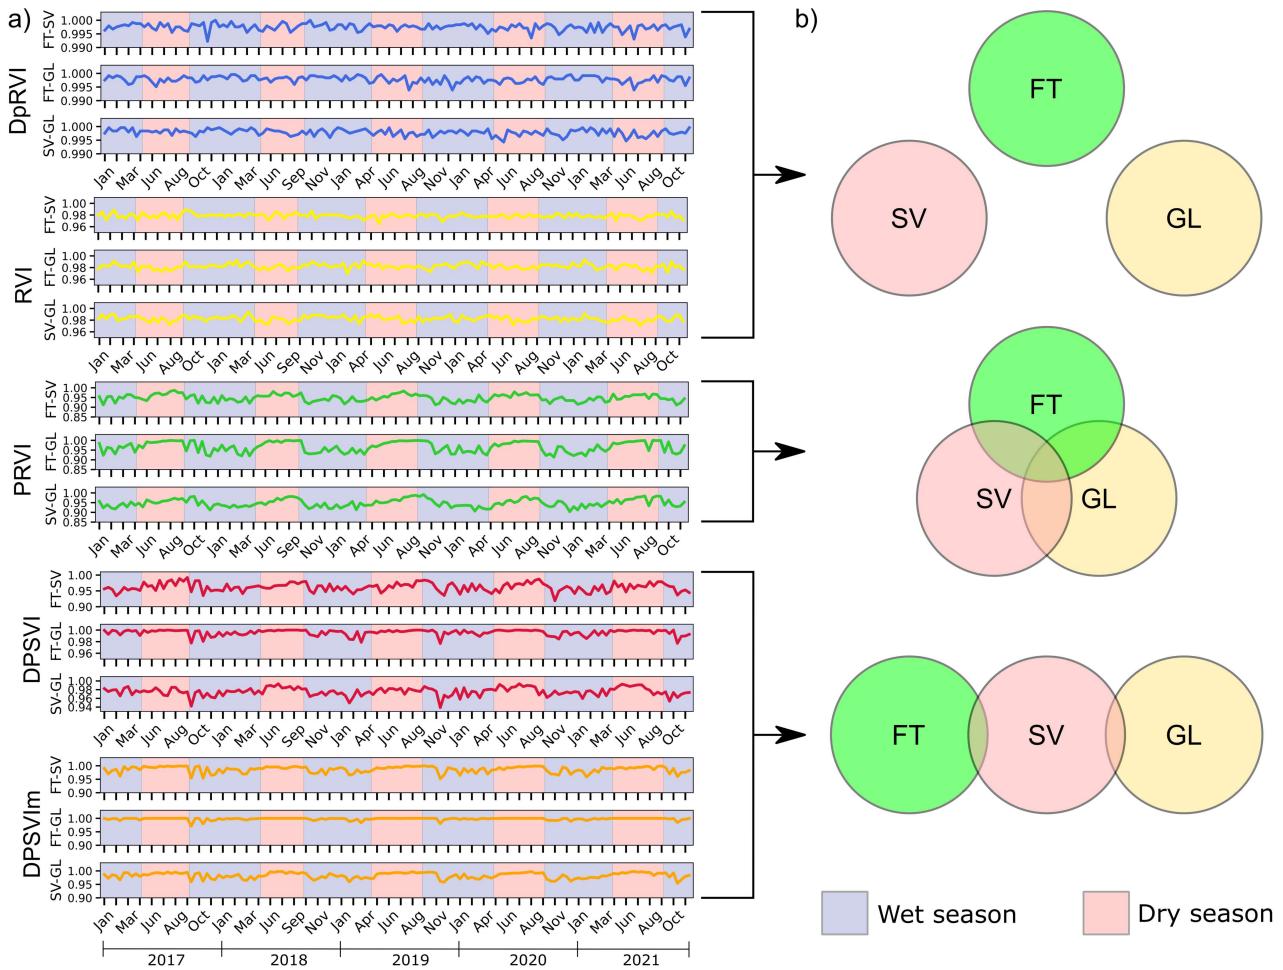


Fig. 12. a) Inter-class profiles of H0 rejection rates ($p < 0.05$). The increase of the H0 rejection rate suggests an increase in the separability. b) Venn diagrams representing the types of separability between the classes.

over the classes, the same principle behind DpRVI and RVI. Furthermore, the CR classes' curves presented an inverse behavior with its respective VDDPI curves (Figure 9). It is possible to observe that CR presented higher amplitude in its variations than VDDPI, despite showing similar trends with a high overlap between its spatial distributions over time. [21] points out that CR has an exponential behavior as a function of VDDPI, which better distinguishes vegetation pixels.

The findings on DPSVIm temporal behavior showed that the seasonal patterns of the BNP vegetation can be useful to interpreting the index results variations in a time series. From the classes' temporal profiles, it is possible to understand the temporal dynamics of the Brazilian Cerrado physiognomies and formulate strategies for monitoring the preserved areas. Giving the potential good separability between the classes, the major physiognomies of Brazilian Cerrado would be discriminable in supervised classification efforts.

DPSVIm can base efforts to reconstruct cloud-affected images from multi-spectral sensors, as investigated by [54]. The authors found that DPSVIm was one of the most important SAR parameters in the reconstruction of cloud-affected Landsat 8 imagery by modelling NDVI and EVI.

F. Hypothesis tests over Kullback-Leibler distances

The temporal profiles of the five SAR vegetation indices presented a first approach about the separability between classes throughout the seasons. The indices' curves indicated that the seasonality effect on the classes' whole spatial extent is observed as a shift to closer distances in its spatial distributions, mainly on wet seasons. PRVI, DPSVI, and DPSVIm presented an increase in class separability in the dry seasons, followed by a decrease in the wet seasons. Inversely, DpRVI and RVI presented a seasonal behavior where the separability between classes increased in the wet seasons and decreased in the dry season.

The hypothesis tests were conducted to assess how distinguishable the classes are from each other over the seasons based on stochastic distances. The tests compared the sample distributions of three different pairs of classes (FT-SV, FT-GL, and SV-GL) under the null hypothesis that two sample distributions can be described by the same distribution. The temporal profiles of H0 rejection rates between different pairs of class patches are shown in Figure 12. The temporal average rates of H0 rejection are shown in Table I.

All curves of DpRVI indicate that the separability between different pairs of classes is not significantly affected by the

TABLE I
TEMPORAL AVERAGE OF H0 REJECTION RATES (%)

	DpRVI	RVI	PRVI	DPSVI	DPSVIm
FT-SV	99.7	97.9	94.8	96.2	98.9
FT-GL	99.8	98.2	96.7	99.6	99.8
SV-GL	99.8	98.2	94.8	97.6	98.3

rainfall seasonality. The seasonal variations did not present any recognizable seasonal pattern and showed a slight difference between the temporal development for each pair. The lack of seasonal pattern in the H0 rejection rate curves might be an expression of the low sensitivity of the index to seasonal influences. The average rates of H0 rejection remained above 99.7% (Table I) in all seasons for all pairs of classes, indicating that DpRVI patch distribution separability is almost complete over time.

Similar to DpRVI, the RVI curves indicate that the separability between the pairs of classes does not change significantly over time as a function of the rainfall seasonality. The seasonal variations did not demonstrate a clear seasonal pattern, and the three pairs of classes had an almost constant temporal development. The index average rates of H0 rejection remained above 97.9% in all seasons for all pairs of classes.

The PRVI curves had a seasonality-influenced behavior where all pairs of classes' curves had a similar temporal behavior. The curves for different pairs of classes had a clear link with the seasons, with a bell-shaped temporal development. The dry seasons presented higher rates of H0 rejection than the wet seasons, sometimes reaching 100% of H0 rejection, especially the Forest-Grassland pair. The decrease in H0 rejection rates in the wet seasons indicate that the seasonality effect indeed approximated the PRVI patch distributions in the wet seasons. The index average rates of H0 rejection remained above 94.8% in all seasons for all pairs of classes, the lowest level of H0 rejection between the studied indices.

The DPSVI curves presented a behavior where each pair had a different temporal development. The separability between Forest and Savanna presented a clear seasonal pattern, increasing in the dry seasons and decreasing in the wet seasons, with an average of 96.2% of H0 rejection. The curve of Forest and Grassland indicates an almost total separability between the classes in the dry seasons, with an average H0 rejection rate of 99.6%. The pair Savanna-Grassland also developed within a seasonal pattern, increasing in the dry seasons and decreasing in the wet seasons, with an average of 97.6% of H0 rejection.

For DPSVIm, similar to DPSVI, each pair of classes had a different behavior regarding seasonality. The Forest-Savanna pair curve had a clear seasonal development, increasing in the dry seasons and decreasing in the wet seasons with an average of 98.9% of H0 rejection along the time series. The Savanna-Grassland curve also shows a clear seasonal development, where the H0 rejection rates had an average of 99.8% throughout the seasons. The Forest-Grassland curve was nearly constant in the time series, where the H0 rates were almost 100%, with an average of 98.3% along the time series.

Beyond the level of separability, the H0 rejection rates' curves also evidence the kind of separability that each index can offer (Figure 12b). The DpRVI and RVI curves indicate a disjoint relationship of the three classes despite the seasonality effects ($FT \cap SV = \emptyset, SV \cap GL = \emptyset, GL \cap FT = \emptyset$). The PRVI curves denote that all classes have associative intersections with each other ($FT \cap SV, SV \cap GL, GL \cap FT$) all over the time series. In this case, seasonality influences the degree of intersection between classes. DPSVI and DPSVIm provide a type of class separability where Forest and Grassland only intersect Savanna over time ($FT \cap SV \cap GL, FT \cap GL = \emptyset$).

The pairs of classes' curves for all indices presented high rates of H0 rejection over time, where most of the averages were above 94% of H0 rejection. Those rates contrast with several studies that assessed the similarity between sample features distributions and segments of SAR images [42] [55] [56]. Those studies reports H0 rejection rates below 1%, for different modeled distributions and stochastic distances. This divergence might be related with the distribution model selection. It is possible that the log-normal can not be the adequate to model the indices' distributions in the spatial domain. Further investigations are necessary to assess the model selection on the H0 rejection rates.

In the context of this study, there is a contrast between the classes' separability observed from the temporal profiles and the separability measured by the hypothesis tests. The temporal profiles showed a high similarity between the classes' distributions over time, which is suggested by the high overlap of the curves that encompass all pixels of each class. The H0 rejection rates suggest an almost complete separability of sample distributions over the seasons. This scenario leads to the assumption that the observed H0 rejection rates can also be related with the classes' patch size (in pixels).

This assumption is supported by the results from [42]. The authors observed that the size of the samples influenced the rate of H0 rejection, when comparing segments of SIR-C L-band simulated data against samples of 9 different classes of real SAR data. The results for Kullback-Leibler distances showed that, as the segments' sizes increased, the percentage of simulated segments for which H0 was not rejected at 5% significance level also increased. [57] found that the mean Kolmogorov-Smirnov distances between distributions modeled by Generalized Gamma, Gamma, and Weibull distributions decreased as the sample sizes increased. [56] also observed that the H0 rejection rates decreased as the sample sizes increased for Kullback-Leibler distances between \mathcal{G}^0 McKay bivariate distributions. If the same is valid for the case of this study, the increase on the patches' size might lead to a decrease on the H0 rejection rates.

Since the patches of 400 pixels used in this study only characterize local variations of those indices, the small pieces of the complete distributions can be influenced by its respective spatial locations. Hence, a possible explanation for the observed H0 rejection rates is that it might be caused by the spatial variability of sample distributions. By increasing the size of the patches, the spatial variability influence on the patch distributions might decrease, leading to more acceptance of the H0. However, larger patches carry a larger mixture of

random variables, which leads to an unwanted contamination of classes' patch distributions. Hence, the definition of patches with an equilibrium between statistical representativeness and the spatial context it is a key matter in the reliability of the test results. Further investigations are necessary to understand the influence of the patch size in H₀ rejection rates for the studied classes.

The speckle noise level in the imagery can be another influence on the high H₀ rejection rates. It is possible that the level of speckle on C2 components and on the backscattering coefficients contributes to add randomness in the classes' index spatial distributions, and thus influences tests results. Further research is necessary to understand the indirect influence of speckle filters and their kernel sizes in the H₀ rejection rates.

Despite its high values, all indices' H₀ rejection curves validate the observations made from the temporal profiles, and evidence potential applications for each index. The DpRVI and RVI's almost constant curves of H₀ rejection rates indicate that both indices presented a low sensitivity to the seasonality effects, which did not significantly change the target's scattering processes. Those indices can be used to monitor defined spatial extents of Cerrado physiognomies, as a proxy of the temporal stability of the vegetation.

On the other hand, PRVI, DPSVI, and DPSVIm curves showed a clear seasonal influence on the H₀ rejection, which also validates the temporal profiles observations. The spatial distributions of those indices were indeed affected by the rainfall regime and its influence on the phenological stages of the vegetation classes. The indices' sensitivity to different biomass levels grants a special type of separability, which allows them to distinguish Forest and Grassland in both wet and dry seasons. Those types of separability can be taken into account when selecting features for mapping the Cerrado physiognomies.

IV. CONCLUSION

This study explored the spatio-temporal behavior of five SAR vegetation indices over classes that represent three Cerrado physiognomies: Forest, Savanna, and Grassland. The data was summarized in terms of spatial median, interquartile range, and standard deviation extracted from every single date within the classes' spatial extents. The temporal profiles constructed for the 2017-2021 period demonstrated the capacity of the indices to describe the vegetation in the BNP. For all indices' profiles, the precipitation was found to be the main driver for the peaks, and vegetation structure changes were the main driver for the shape of the curves (upward and downward trends).

The classes' DpRVI and RVI temporal behaviors were found to follow the characteristic seasonal pattern in BNP, increasing in the wet seasons and decreasing in the dry seasons. However, the seasonality effect was found not sufficient to change the indices' spatial distributions over time. The temporal profiles showed high overlaps between the classes' spatial distributions of both indices over time, presenting low separability between all classes despite the seasonality influence. In the spatial domain the result was maps with fuzzy aspect and no recognizable class spatial pattern in both wet and dry season examples.

DpRVI and RVI distinguish the classes by the rate of C-band signal variations, which are linked with the phenology and architecture of the vegetation within the classes.

The classes' temporal behaviors of PRVI, DPSVIm, and DPSVI were also found to follow the BNP seasonal pattern in approximately bell-shaped curves, distinguishing the classes by the biomass level. The increase in the indices in wet seasons was observed by a shift on all classes' spatial distributions to almost the same levels, which led to lower separability between classes. Especially on rainy dates, a phenomenon here called index equalization was observed, where precipitation often raised all classes' medians to almost the same values, nearly to a saturation value. In contrast, the decrease in the indices' values on the dry seasons enhanced the classes' separability. This scenario was reinforced by the example maps of all indices, which showed clearer differentiation between classes in the dry seasons than in the wet seasons.

The analysis based on Kullback-Leibler stochastic distances validated the observations made with the temporal profiles. DpRVI and RVI H₀ rejection rates' curves of all pairs of classes did not follow a clear seasonal pattern, evidencing that seasonality is not the main driver for those indices' variations. PRVI, DPSVI, and DPSVIm H₀ rejection rates followed the typical seasonal pattern in BNP, reinforcing that seasonality directly influences the indices' response in the spatial domain over time.

The indices can be categorized in three groups based on the type of separability offered. The first group is composed by DpRVI and RVI, which presented a complete disjoint relationship between the classes, contrasting with the observations made with temporal profiles. This kind of separability was hypothesized to be mainly influenced by the classes' size of sample distributions. The second group is composed only by PRVI, which presented associative intersections between classes all over the time series. The third group is composed by DPSVI and DPSVIm, which showed complete separability between Forest and Grassland. Both classes only intersected Savanna along the DPSVIm time series, and the degree of intersection was influenced by seasonality.

Based on the results of this study it can be concluded that the five SAR vegetation indices effectively describe the Cerrado physiognomies. Based on the scattering randomness of the targets, DpRVI and RVI have potential to be used as proxies of the temporal stability of vegetation in previously mapped areas. By describing the vegetation by the biomass level, PRVI, DPSVI, and DPSVIm have the potential to be used as predictor variables to map the Cerrado physiognomies. The different potential of the indices to describe vegetation combined with the Sentinel-1' revisit time of 12 days configure a propitious scenario to monitor the Cerrado physiognomies, especially in regions where the cloud cover decreases the availability of optical satellite data.

APPENDIX A DATASETS AND SOURCE CODE LINKS

The data derived from the C2 matrix and backscatter coefficients imagery, as well as the Python scripts' source codes of

preprocessing pipelines, vegetation indices processing, spatial statistics extraction, temporal profiles, and stochastic distance analysis notebooks can be found in the following link:

https://github.com/JalesBussinguer/thesis_code

APPENDIX B

PROOF OF THE KULLBACK-LEIBLER STOCHASTIC DISTANCE BETWEEN TWO LOG-NORMAL DISTRIBUTIONS

The Kullback-Leibler divergence measure between two log-normal distributions, parameterized in terms of mean (μ) and standard deviation (σ) is [58]:

$$D_{LN}(\hat{\theta}_p|\hat{\theta}_q) = \ln\left(\frac{\sigma_p}{\sigma_q}\right) + \frac{1}{2\sigma_q^2} [(\mu_p - \mu_q)^2 + \sigma_p^2 - \sigma_q^2]$$

Since the stochastic distance is a symmetric version of the divergence measure [40]:

$$d_{LN}(\hat{\theta}_p|\hat{\theta}_q) = \frac{D(\hat{\theta}_p|\hat{\theta}_q) + D(\hat{\theta}_q|\hat{\theta}_p)}{2}$$

The Kullback-Leibler stochastic distance between two log-normal distributions is given by:

$$\begin{aligned} d_{LN}(\hat{\theta}_p|\hat{\theta}_q) &= \left[\ln\left(\frac{\sigma_p}{\sigma_q}\right) + \frac{1}{2\sigma_q^2} [(\mu_p - \mu_q)^2 + \sigma_p^2 - \sigma_q^2] \right. \\ &\quad \left. + \ln\left(\frac{\sigma_q}{\sigma_p}\right) + \frac{1}{2\sigma_p^2} [(\mu_q - \mu_p)^2 + \sigma_q^2 - \sigma_p^2] \right] \times \frac{1}{2} \\ &= [\ln(\sigma_q) - \ln(\sigma_p) + \ln(\sigma_p) - \ln(\sigma_q) + \\ &\quad \frac{1}{2\sigma_q^2\sigma_p^2} \times \sigma_p^2[(\mu_p - \mu_q)^2 + \sigma_p^2 - \sigma_q^2] + \sigma_q^2[(\mu_q - \mu_p)^2 + \sigma_q^2 - \sigma_p^2]] \times \frac{1}{2} \\ &= \frac{\sigma_p^2(\mu_p - \mu_q)^2 + \sigma_q^2(\mu_q - \mu_p)^2 + (\sigma_p^4 - 2\sigma_p^2\sigma_q^2 + \sigma_q^4)}{4\sigma_q^2\sigma_p^2} \end{aligned}$$

Note that,

$$\begin{aligned} a^2 - 2ab + b^2 &= (a - b)^2 \rightarrow (\sigma_p^4 - 2\sigma_p^2\sigma_q^2 + \sigma_q^4) = (\sigma_p^2 - \sigma_q^2)^2 \\ a &= \sigma_p^2, \quad b = \sigma_q^2 \end{aligned}$$

Hence,

$$d_{LN}(\hat{\theta}_p|\hat{\theta}_q) = \frac{\sigma_p^2(\mu_p - \mu_q)^2 + \sigma_q^2(\mu_q - \mu_p)^2 + (\sigma_p^2 - \sigma_q^2)^2}{4\sigma_p^2\sigma_q^2}$$

ACKNOWLEDGMENT

The authors would like to thank the European Space Agency (ESA) and the Alaska Satellite Facility (ASF) for providing the Sentinel-1 SLC and GRD products through the ASF portal.

A special thanks to Andre Bindilatti for his contribution to the stochastic distances experimental design and code.

Another special thanks to Erli Santos for his insights and comments on the DPSVI and DPSVIm temporal profiles.

This research was supported by Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brazil (CAPES).

This work is dedicated to the memory of Andre Matos.

REFERENCES

- [1] E. E. Sano, R. Rosa, C. A. de Mattos Scaramuzza, M. Adami, E. L. Bolfe, A. C. Coutinho, J. C. D. M. Esquerdo, L. E. P. Maurano, I. da Silva Narvaes, F. J. B. de Oliveira Filho, E. B. da Silva, D. de Castro Victoria, L. G. Ferreira, J. L. S. Brito, A. P. Bayma, G. H. de Oliveira, and G. Bayma-Silva, "Land use dynamics in the brazilian cerrado in the period from 2002 to 2013," *Pesquisa Agropecuária Brasileira*, vol. 54, 2019.
- [2] B. B. N. Strassburg, T. Brooks, R. Feltran-Barbieri, A. Iribarrem, R. Crouzeilles, R. Loyola, A. E. Latawiec, F. J. B. O. Filho, C. A. de Mattos Scaramuzza, F. R. Scarano, B. Soares-Filho, and A. Balmford, "Moment of truth for the cerrado hotspot," *Nature Ecology Evolution*, vol. 54, no. 0099, 2017.
- [3] M. M. C. Bustamante, G. B. nardoto, A. S. Pinto, J. C. F. Resende, F. S. C. Takahashi, and L. C. G. Vieira, "Potential impacts of climate change on biogeochemical functioning of cerrado ecosystems," *Brazilian Journal of Biology*, vol. 72, no. 3, pp. 655–671, 2012.
- [4] C. Joly, C. Padgurschi, A. A. A.P.F. Pires, A. Marques, A. Amaral, C. Cervone, C. C. Adams, F. Baccaro, G. Sparovek, G. Overbeck, G. Espindola, I. Vieira, J. Metzger, J. Sabino, J. Farinaci, L. Queiroz, L. Gomes, M. Cunha, M. Piedade, M. Bustamante, P. May, P. Fearnside, R. Prado, and R. Loyola, *Apresentando o diagnóstico brasileiro de biodiversidade e serviços ecossistêmicos*. São Carlos, Brazil: Editora Cubo, 2019.
- [5] C. A. Klink and R. B. Machado, "Conservation of the brazilian cerrado," *Conservation Biology*, vol. 19, no. 3, pp. 707–713, 2005.
- [6] R. Mittermeier, P. Gil, M. Hoffmann, J. Pilgrim, T. Brooks, C. Mittermeier, J. Lamoreux, and G. Da Fonseca, *Hotspots Revisited: Earth's Biologically Richest and Most Endangered Terrestrial Ecoregions: Conservation International*. Sierra Madre, Cemex: University of Chicago Press, 2005.
- [7] S. A. Spera, G. L. Galford, M. T. Coe, M. N. Macedo, and J. F. Mustard, "Land-use change affects water recycling in brasil's last agricultural frontier," *Global Change Biology*, vol. 22, no. 10, pp. 3405–3413, 2016.
- [8] A. Alencar, J. Z. Shimbo, F. Lenti, C. B. Marques, B. Zimbres, M. Rosa, V. Arruda, I. Castro, J. P. F. M. Ribeiro, V. Varela, I. Alencar, V. Piontekowski, V. Ribeiro, M. M. C. Bustamante, E. E. Sano, and M. Barroso, "Mapping three decades of changes in the brazilian savanna native vegetation using landsat data processed in the google earth engine platform," *Remote Sensing*, vol. 12, no. 6, 2020.
- [9] L. F. F. G. Assis, K. R. Ferreira, L. Vinhas, L. Maurano, C. Almeida, A. Carvalho, J. Rodrigues, A. Maciel, and C. Camargo, "Terrabrasilis: A spatial data analytics infrastructure for large-scale thematic mapping," *ISPRS International Journal of Geo-Information*, vol. 8, no. 11, 2016.
- [10] A. Alencar, J. Z. Shimbo, V. Piontekowski, D. Concianni, J. Doblas, T. Andrade, and F. Lenti, "Relatório sad cerrado (2022)," Amazonian Environmental Research Institute (IPAM), Technical Report, 2022. [Online]. Available: https://datastudio.google.com/u/0/reporting/23972c36-305f-48d5-9324-35b1646a033d/page/p_vnveat17x
- [11] E. E. Sano, P. Rizzoli, C. N. Koyama, M. Watanabe, M. Adami, Y. E. Shimabukuro, G. Bayma, and D. M. Freitas, "Comparative analysis of the global forest/non-forest maps derived from sar and optical sensors. case studies from brazilian amazon and cerrado biomes," *Remote Sensing*, vol. 13, no. 3, 2021.
- [12] E. E. Sano, G. G. Pinheiro, and P. R. Menezes, "Assessing JERS-1 synthetic aperture data for vegetation mapping in the Brazilian Savanna," *Journal of The Remote Sensing Society of Japan*, vol. 21, no. 2, pp. 158–167, 2001.
- [13] E. E. Sano, L. G. Ferreira, and A. R. Huete, "Synthetic aperture radar (l band) and optical vegetation indices for discriminating the brazilian savanna physiognomies: A comparative analysis," *Earth Interactions*, vol. 9, no. 15, p. 15, 2005.
- [14] F. d. S. Mendes, D. Baron, G. Gerold, V. Liesenberg, and S. Erasmi, "Optical and SAR remote sensing synergism for mapping vegetation types in the endangered Cerrado/Amazon ecotone of Nova Mutum-Mato Grosso," *Remote Sensing*, vol. 11, no. 10, 2019.
- [15] P. d. C. Bispo, P. Rodriguez-Veiga, B. Zimbres, S. do Couto de Miranda, C. Henrique Giusti Cezare, S. Fleming, F. Baldacchino, V. Louis, D. Rains, M. Garcia, F. Del Bon Espírito-Santo, I. Roitman, A. M. Pacheco-Pascagaza, Y. Gou, J. Roberts, K. Barrett, L. G. Ferreira, J. Z. Shimbo, A. Alencar, M. Bustamante, I. H. Woodhouse, E. Eyji Sano, J. P. Ometto, K. Tansey, and H. Balzter, "Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach," *Remote Sensing*, vol. 12, no. 17, 2020.

- [16] B. Zimbres, P. Rodríguez-Veiga, J. Z. Shimbo, P. da Conceição Bispo, H. Balzter, M. Bustamante, I. Roitman, R. Haidar, S. Miranda, L. Gomes, F. Alvim Carvalho, E. Lenza, L. Maracahipes-Santos, A. C. Abadia, J. A. do Prado Júnior, E. L. Mendonça Machado, A. P. Dias Gonzaga, M. de Castro Nunes Santos Terra, J. M. de Mello, J. R. Soares Scolforo, J. R. Rodrigues Pinto, and A. Alencar, "Mapping the stock and spatial distribution of aboveground woody biomass in the native vegetation of the Brazilian Cerrado biome," *Forest Ecology and Management*, vol. 499, no. 10, 2021.
- [17] K. Lewis, F. V. de Barros, M. B. Cure, C. A. Davies, M. N. Furtado, T. C. Hill, M. Hirota, D. L. Martins, G. G. Mazzochini, E. T. A. Mitchard, C. B. R. Munhoz, R. S. Oliveira, A. Sampaio, N. A. Saraiva, I. B. Schmidt, and L. Rowland, "Beyond trees: Mapping total aboveground biomass density in the brazilian savanna using high-density uav-lidar data," *Scientific Reports*, vol. 12, no. 1588, p. 17, 2021.
- [18] J. G. Chang, M. Shoshany, and Y. Oh, "Polarimetric radar vegetation index for biomass estimation in desert fringe ecosystems," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, no. 12, pp. 7102–7108, 2018.
- [19] S. Periasamy, "Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1," *Remote Sensing of Environment*, no. 217, pp. 537–549, 2018.
- [20] R. Nasirzadehdjazi, F. B. Sanli, S. Abdikan, Z. CAkir, A. Sekertekin, and M. Ustuner, "Sensitivity analysis of multi-temporal Sentinel-1 SAR parameters to crop height and canopy coverage," *Applied Sciences*, vol. 665, no. 9, pp. 7581–7609, 2019.
- [21] E. P. dos Santos, D. D. da Silva, and C. H. do Amaral, "Vegetation cover monitoring in tropical regions using SAR-C dual-polarization index: seasonal and spatial influences," *International Journal of Remote Sensing*, vol. 42, no. 19, pp. 7581–7609, 2021.
- [22] D. Mandal, V. Kumar, D. Ratha, S. Dey, A. Bhattacharya, J. M. Lopez-Sanchez, H. McNairn, and Y. S. Rao, "Dual polarimetric radar vegetation index for crop growth monitoring using sentinel-1 sar data," *Remote Sensing of Environment*, vol. 247, p. 111954, 2020.
- [23] R. D. Ottmar, R. E. Viñanek, H. S. Miranda, M. N. Sato, and S. M. A. Andrade, "Stereo photo series for quantifying cerrado fuels in central brazil - volume i," U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, Portland, OR, General Technical Report PNW-GTR-519, 2001.
- [24] M. B. T. da Costa, C. A. Silva, E. N. Broadbent, R. V. Leite, M. Mohan, V. Liesenberg, J. Stoddart, C. H. do Amaral, D. R. A. de Almeida, A. L. da Silva, L. R. Ré Y. Goya, V. A. Cordeiro, F. Rex, A. Hirsch, G. E. Marcatti, A. Cardil, B. A. F. de Mendonça, C. Hamamura, A. P. D. Corte, E. A. T. Matricardi, A. T. Hudak, A. M. A. Zambrano, R. Valbuena, B. L. de Faria, C. H. Silva Junior, L. Aragao, M. E. Ferreira, J. Liang, S. de Pádua Chaves e Carvalho, and C. Klauberg, "Beyond trees: Mapping total aboveground biomass density in the brazilian savanna using high-density uav-lidar data," *Forest Ecology and Management*, vol. 491, no. 119155, p. 15, 2021.
- [25] S. N. de Levantamento e Conservação de Solos, "Sumula da x reunião técnica de levantamento de solos," Empresa Brasileira de Pesquisa Agrícola - EMBRAPA., Misc series 1, march 1979.
- [26] J. Ribeiro and T. Walter, "The major physiognomy in the brazilian cerrado region," in *Cerrado: Ambiente e Flora*, S. Sano and S. Almeida, Eds. Planaltina, DF, Brazil: EMBRAPA-CPAC, 2008, ch. 3, pp. 169–1886, (in Portuguese).
- [27] MapBiomass Project - Brasil. [Online]. Available: <https://mapbiomas.org/en>
- [28] G. Sarmiento and M. Monasterio, "Life forms and phenology," in *Ecosystems of the Worlds XIII*, F. Bourliere, Ed. Amsterdam, The Netherlands: Elsevier, 1983, ch. 5, pp. 79–108.
- [29] P. E. A. M. de Oliveira, "Phenology and reproductive biology of cerrado's species," in *Cerrado: Ambiente e Flora*, S. Sano, S. Almeida, and J. F. Ribeiro, Eds. Brasília, DF, Brazil: EMBRAPA Cerrados, 2008, ch. 9, pp. 275–290, (in Portuguese).
- [30] R. Barakat, "Degree of polarization and the principal idempotents of the coherency matrix," *Optics Communications*, vol. 23, pp. 147–150, 1977.
- [31] Y. Kim and J. J. Van Zyl, "A time-series approach to estimate soil moisture using polarimetric radar data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 8, pp. 2519–2527, 2009.
- [32] Y. Kim, T. Jackson, R. Bindlish, H. Lee, and S. Hong, "Radar Vegetation Index for Estimating the Vegetation Water Content of Rice and Soybean," *IEEE Geoscience and Remote Sensing Letters*, vol. 9, no. 4, pp. 564–568, 2012.
- [33] C. Szigarski, T. Jagdhuber, M. Baur, C. Thiel, M. Parrens, J.-P. Wigneron, M. Piles, and D. Entekhabi, "Analysis of the Radar Vegetation Index and Potential Improvements," *Remote Sensing*, vol. 10, no. 1776, p. 15, 2018.
- [34] M. Trudel, F. Charbonneau, and R. Leconte, "Using RADARSAT-2 polarimetric and ENVISAT-ASAR dual-polarization data for estimating soil moisture over agricultural fields," *Canadian Journal of Remote Sensing*, vol. 38, no. 4, pp. 514–527, 2012.
- [35] F. Charbonneau, M. Trudel, and R. Fernandes, "Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping," in *Proceedings of the 2005 Advanced Synthetic Aperture Radar (ASAR) Workshop*, St-Hubert, QC, Canada, 2005, pp. 15–17.
- [36] K. R. Raney, J. T. Cahill, G. Patterson Wesley, and D. B. J. Bussey, "The m-chi decomposition of hybrid dual-polarimetric radar data with application to lunar craters," *Journal of Geophysical Research E: Planets*, vol. 117, no. 5, pp. 1–8, 2012.
- [37] N. Bhogaprapu, S. Dey, D. Mandal, A. Bhattacharya, and Y. S. Rao, "PolSAR tools: A QGIS plugin for generating SAR descriptors," *Journal of Open Source Software*, vol. 6, no. 60, p. 2970, 2021.
- [38] P.-L. Frison, B. Fruneau, S. Kmih, K. Soudani, E. Dufrêne, T. L. Toan, T. Koleck, L. Villard, E. Mougin, and J.-P. Rudant, "Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology," *Remote Sensing*, vol. 10, no. 12, p. 10, 2018.
- [39] J.-S. Lee, "Refined filtering of image noise using local statistics," *Computer Graphics and Image Processing*, vol. 15, no. 4, pp. 380–389, 1981.
- [40] A. D. Nascimento, R. J. Cintra, and A. C. Frery, "Hypothesis Testing in Speckled Data with Stochastic Distances," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 1, pp. 373–385, 2010.
- [41] A. A. Bindilatti and N. D. A. Mascarenhas, "A nonlocal poisson denoising algorithm based on stochastic distances," *IEEE Signal Processing Letters*, vol. 20, no. 11, pp. 1010–1013, 2013.
- [42] W. B. Silva, C. C. Freitas, S. J. Sant'Anna, and A. C. Frery, "Classification of segments in polsar imagery by minimum stochastic distances between wishart distributions," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 6, no. 3, pp. 1263–1273, 2013.
- [43] N. Bouhlel, V. Akbari, and S. Méric, "Change detection in multilook polarimetric sar imagery with determinant ratio test statistic," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–15, 2022.
- [44] J. Doblas, A. C. Frery, S. J. S. Sant'Anna, A. Carneiro, and Y. E. Shimabukuro, "Assessment of nonlocal means stochastic distances speckle reduction for sar time series," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021, pp. 3265–3268.
- [45] V. P. Yadav, R. Prasad, R. Bala, P. K. Srivastava, and V. S. Vanama, "Appraisal of dual polarimetric radar vegetation index in first order microwave scattering algorithm using sentinel-1a (c - band) and alos - 2 (l - band) sar data," *Geocarto International*, vol. 0, no. 0, pp. 1–19, 2021.
- [46] J. Doblas, Y. Shimabukuro, S. Sant'Anna, A. Carneiro, L. Aragão, and C. Almeida, "Optimizing near real-time detection of deforestation on tropical rainforests using sentinel-1 data," *Remote Sensing*, vol. 12, no. 3922, p. 31, 2020.
- [47] A. Allies, A. Rourmiguié, J.-F. Dejoux, R. Fieuzal, A. Jacquin, A. Veloso, L. Champolivier, and F. Baup, "Evaluation of multiorbital sar and multisensor optical data for empirical estimation of rapeseed biophysical parameters," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 7268–7283, 2021.
- [48] A. K. Maurya, N. Bhargava, and D. Singh, "Efficient selection of sar features using ml based algorithms for accurate fvc estimation," *Advances in Space Research*, vol. 70, no. 7, pp. 1795–1809, 2022.
- [49] D. Halder, A. Verma, S. Kumar, and P. Chauhan, "Estimation of mustard and wheat phenology using multi-date shannon entropy and radar vegetation index from polarimetric sentinel-1," *Geocarto International*, vol. 37, no. 20, pp. 5935–5962, 2021.
- [50] G. D. Luca, J. M. N. Silva, and G. Modica, "A workflow based on sentinel-1 sar data and open-source algorithms for unsupervised burned area detection in mediterranean ecosystems," *GIScience and Remote Sensing*, vol. 58, no. 4, pp. 516–541, 2021.
- [51] B. Vaghela, S. Chirakkal, D. Putrevu, and H. Solanki, "Modelling above ground biomass of indian mangrove forest using dual-pol sar data," *Remote Sensing Applications: Society and Environment*, vol. 21, no. 100457, p. 12, 2021.
- [52] G. D. Luca, J. M. N. Silva, and G. Modica, "Short term temporal and spatial analysis for post-fire vegetation regrowth characterization and mapping in a mediterranean ecosystem using optical and sar image time-series," *Geocarto International*, pp. 1–35, 2022.

- [53] L. Sosa, A. Justel, and Íñigo Molina, "Detection of crop hail damage with a machine learning algorithm using time series of remote sensing data," *Agronomy*, vol. 11, no. 2078, p. 18, 2021.
- [54] E. P. dos Santos, D. D. da Silva, C. H. do Amaral, E. I. Fernandes-Filho, and R. L. S. Dias, "A machine learning approach to reconstruct cloudy affected vegetation indices imagery via data fusion from sentinel-1 and landsat 8," *Computers and electronics in Agriculture*, vol. 194, no. 106753, p. 12, 2022.
- [55] A. Nascimento, J. Ferreira, and A. Silva, "Divergence-based tests for the bivariate gamma distribution applied to polarimetric synthetic aperture radar," *Statistical Papers*, pp. 1–25, 2022.
- [56] A. Silva and A. Nascimento, "A novel bivariate distribution and its divergence-based hypothesis inference: an application to the deforestation focus detection," *International Journal of Remote Sensing*, vol. 44, no. 1, pp. 1–29, 2023.
- [57] X. Qin, H. Zou, S. Zhou, and K. Ji, "Divergence-based tests for the bivariate gamma distribution applied to polarimetric synthetic aperture radar," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 8, pp. 1655–1659, 2015.
- [58] D. Dittrich, "Statistical Methods for Estimating Loss Distributions," Master's thesis, Technische Universität München, München, Germany, 2013.

6 Conclusão

Esta dissertação traz um estudo exploratório do comportamento espaço-temporal de índices SAR de vegetação no Parque Nacional de Brasília. O objetivo principal foi verificar a capacidade de tais índices em descrever a dinâmica sazonal de três fitofisionomias de Cerrado, organizadas em classes. O principal critério analisado foi o nível de separabilidade entre as três classes nas estações úmidas e secas da região de estudo, medido por meio de testes de hipótese baseados em distâncias estocásticas de distribuições amostrais espaciais.

O trabalho foi desenvolvido em duas partes. Na primeira parte, a pesquisa abordou o comportamento espaço-temporal de dados SAR em termos de intensidade de retroespalhamento e variáveis polarimétricas (entropia e ângulo alfa) na região do Parque Nacional de Brasília. Tais análises constituíram uma etapa-base para a compreensão da interação do sinal de banda C dos radares da constelação Sentinel-1 com a vegetação das fitofisionomias de Cerrado contidas na região estudada. A partir dessa construção, a segunda parte traz uma análise de cinco índices SAR de vegetação como descritores da dinâmica sazonal da vegetação no PNB, em formato de artigo a ser submetido em revista internacional revisada por pares. Para todas as etapas da dissertação, foi produzida uma estrutura de código em linguagem Python englobando o preprocessamento dos dados SAR, produção dos rasters dos índices de vegetação, extração das estatísticas zonais, implementação dos testes de hipótese para distâncias estocásticas Kullback-Leibler e a produção dos perfis temporais e demais figuras.

Os resultados da análise polarimétrica indicam que os parâmetros Entropia (H) e Ângulo Alfa (α) descrevem a taxa de variação do sinal de banda C sobre os diferentes estratos vegetativos no PNB. As evidências coletadas indicam que tais parâmetros são sensíveis aos efeitos da sazonalidade no PNB, porém tal influência não é capaz de diferenciar espacialmente as classes de vegetação estudadas. Ao longo da série temporal, em ambas estações úmida e seca, os níveis de entropia se mantiveram em uma faixa intermediária ($0.66 < H < 0.88$), e os níveis de ângulo alfa se mantiveram em níveis baixos ($23.0 < \alpha < 32.5$), segundo a segmentação de Ji e Wu (2015). Além disso, foram observadas altas sobreposições entre as distribuições espaciais das três classes, independente da influência da sazonalidade.

A principal diferenciação entre as classes foi observada no domínio temporal, onde cada classe apresentou um comportamento coerente com as características estruturais de sua vegetação, sendo a classe *Grassland* a classe com maiores taxas de variação no tempo, seguida de *Savanna* e *Forest*, respectivamente. Nesse contexto, os parâmetros polarimétricos se mostraram eficientes na caracterização da estabilidade

temporal da cobertura vegetal. Uma hipótese é então levantada de que eventuais perturbações na vegetação preservada como queimadas e desmate por corte raso levem a um comportamento deviante do que foi observado neste estudo, podendo servir de parâmetro para a geração de alertas.

Da análise de intensidade de retroespalhamento σ^0 , os resultados indicam que ambas polarizações VH e VV demonstram sensibilidade à influência da sazonalidade sobre a vegetação do PNB. Foi observada uma relação diretamente proporcional entre a intensidade de retroespalhamento e o nível de biomassa das classes, isto é, quanto maior o nível de biomassa, maior a intensidade de retroespalhamento em ambas polarizações VH e VV. Além disso, as distribuições espaciais das classes em ambas polarizações apresentam menores sobreposições do que as variáveis polarimétricas. Dessa forma, observou-se que a intensidade do sinal é um parâmetro adequado para o mapeamento das fitofisionomias do Cerrado, com clara separação entre as classes em termos de intensidade do sinal do que em termos de grau de aleatoriedade do sinal.

Na segunda parte deste trabalho, os resultados da análise dos índices SAR de vegetação sugerem que a precipitação é responsável pelos picos dos índices. Já as mudanças na estrutura da vegetação das classes em função da sazonalidade são responsáveis pelas tendências de subida e descida dentro da série temporal. Tais observações foram feitas nos perfis temporais de todos os cinco índices estudados.

Os índices DpRVI e RVI, ambos métricas da aleatoriedade do sinal na interação com a vegetação, se mostraram sensíveis à influência da sazonalidade sobre as classes estudadas. Ambos apresentaram um comportamento temporal crescente nas estações úmidas e decrescente nas estações secas, seguindo o padrão sazonal caraterístico observado para o PNB. Contudo, foi observado que os efeitos da sazonalidade sobre a vegetação no local de estudo não afetaram significativamente as distribuições espaciais em ambos índices. Os perfis temporais de DpRVI e RVI mostraram altos graus de sobreposição das distribuições espaciais das classes, denotando baixa separabilidade dessas tanto nas estações úmidas quanto nas estações e secas no período analisado. No domínio espacial, os resultados foram mapas com ausência de padrões espaciais que permitissem a identificação visual das classes de vegetação em ambas estações.

A partir desses resultados, foi possível concluir que ambos DpRVI e RVI descrevem a vegetação do PNB de forma análoga aos parâmetros polarimétricos analisados anteriormente. Nesse contexto, as evidências coletadas indicam que ambos índices podem ser utilizados como um *proxy* da estabilidade temporal de regiões previamente de vegetação de Cerrado previamente mapeadas. Uma hipótese é então levantada de que eventuais desvios do comportamento observado para regiões preservadas podem

ser tidos como alertas de queimadas e/ou desmate por corte raso. Futuros trabalhos devem testar essa hipótese, aplicando esses índices em áreas com histórico de transformação da paisagem floresta-solo.

Os perfis temporais dos índices PRVI, DPSVI e DPSVIm apresentaram um comportamento sensível ao padrão sazonal observado no PNB, distinguindo as classes de maneira diretamente proporcional ao nível de biomassa. Nas estações úmidas, as distribuições espaciais destes foram deslocadas para valores mais altos com consequente degradação da separabilidade entre as classes. Por outro lado, as tendências decrescentes nas estações secas implicaram em um aumento da separabilidade entre as distribuições espaciais das classes. Tais resultados foram reforçados pela aspecto visual dos mapas-exemplo em cada estação, onde os mapas da estação seca apresentaram diferenças mais evidentes entre as classes do que os mapas da estação úmida.

A partir desses resultados, foi possível concluir que os índices PRVI, DPSVI e DPSVIm descrevem a vegetação do PNB de forma análoga aos coeficientes de retroespalhamento σ^0 . Nesse contexto, as evidências coletadas indicam que ambos índices podem ser utilizados como parâmetros viáveis para o mapeamento do Cerrado via classificação *pixel apixel*. Futuros trabalhos que testem esses índices como variáveis preditoras em esforços de mapeamento do Cerrado são encorajados, de modo a avaliar na prática o ganho de informação que estes índices oferecem.

Além disso, um fenômeno descrito neste trabalho como "equalização de índice" (*index equalization effect*) foi observado em datas chuvosas na série temporal. O fenômeno foi observado como um deslocamento das distribuições espaciais das três classes para um mesmo patamar de valores, com sobreposição quase completa em termos de mediana e IQR. Tal sobreposição ocorreu principalmente em valores de mediana tidos como "ponto de saturação", valores estes de máxima de mediana na série temporal. Tais observações indicam que a precipitação eleva a resposta desses índices até a saturação do sinal da banda C, degradando a sensibilidade destes ao nível de biomassa das classes, com consequente perda de padrões espaciais característicos nos mapas.

Por fim, a análise dos testes de hipótese baseados em distâncias estocásticas validaram as observações feitas a partir dos perfis temporais. As curvas de rejeição da hipótese nula (H_0) dos índices DpRVI e RVI não apresentaram um padrão sazonal claro, evidenciando que a sazonalidade não é o principal condutor das variações na separabilidade das classes. Já para os índices PRVI, DPSVI e DPSVIm, as curvas de rejeição da H_0 demonstraram clara variação dentro do padrão sazonal característico do PNB. Tais observações evidenciam que a sazonalidade influencia diretamente a

reposta no domínio espacial desses índices ao longo do tempo.

A partir dos testes de hipótese foi possível ainda observar os tipos de separabilidade que cada índice oferece em relação às três classes estudadas. Nesse sentido, os índices podem ser separados em três grupos. O primeiro grupo é composto por DpRVI e RVI, que apresentaram uma relação disjunta entre as classes, contrastando com as observações feitas a partir dos perfis temporais. Foi levantada a hipótese de que esse tipo de separabilidade pode ter sido principalmente influenciada pelo tamanho das distribuições amostrais utilizadas nos testes. O segundo grupo é composto apenas pelo PRVI, que apresentou interseções associativas entre as classes ao longo de toda série temporal. O terceiro grupo é composto por DPSVI e DPSVIm, que apresentaram separabilidade completa entre as distribuições amostrais das classes *Forest* e *Grassland*. Ambas classes interseccionaram apenas a classe *Savanna* em ambas estações úmida e seca, e o grau de interseção se mostrou influenciado pela sazonalidade.

Com base nos resultados expostos, é possível concluir que todos os cinco índices estudados descrevem efetivamente as fitofisionomias do Cerrado e suas dinâmicas temporais.

Para trabalhos futuros, recomenda-se a análise comparativa entre Sigma0, decomposição polarimétrica H-alpha e índices de vegetação derivados de dados multi-frequência, utilizando principalmente as bandas C e L. Além disso, recomenda-se uma classificação temática pelos métodos de machine learning ou deep learning a partir dos descritores explorados neste trabalho e usando dados de referência obtidos dos mosaicos mensais do Planet (5 m de resolução).

7 BIBLIOGRAFIA

- ALENCAR, A.; SHIMBO, J. Z.; LENTI, F.; MARQUES, C. B.; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, J. P. F. M.; VARELA, V.; ALENCAR, I.; PIONTEKOWSKI, V.; RIBEIRO, V.; BUSTAMANTE, M. M. C.; SANO, E. E.; BARROSO, M. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. *Remote Sensing*, v. 12, n. 6, 2020.
- ALENCAR, A.; SHIMBO, J. Z.; PIONTEKOWSKI, V.; CONCIANI, D.; DOBLAS, J.; ANDRADE, T.; LENTI, F. *Relatório SAD Cerrado (2022)*. [S.I.], 2022. Disponível em: <https://datastudio.google.com/u/0/reporting/23972c36-305f-48d5-9324-35b1646a033d/page/p_vnveat17xc>.
- ARII, M.; ZYL, J. J. van; KIM, Y. A general characterization for polarimetric scattering from vegetation canopies. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, n. 9, p. 3349–3357, 2010.
- ASSIS, L. F. F. G.; FERREIRA, K. R.; VINHAS, L.; MAURANO, L.; ALMEIDA, C.; CARVALHO, A.; RODRIGUES, J.; MACIEL, A.; CAMARGO, C. Terrabrasilis: A spatial data analytics infrastructure for large-scale thematic mapping. *ISPRS International Journal of Geo-Information*, v. 8, n. 11, 2016.
- BARAKAT, R. Degree of polarization and the principal idempotents of the coherency matrix. *Optics Communications*, v. 23, p. 147–150, 1977.
- BISPO, P. d. C.; RODRIGUEZ-VEIGA, P.; ZIMBRES, B.; MIRANDA, S. do Couto de; CEZARE, C. H. G.; FLEMING, S.; BALDACCHINO, F.; LOUIS, V.; RAINS, D.; GARCIA, M.; ESPÍRITO-SANTO, F. D. B.; ROITMAN, I.; PACHECO-PASCAGAZA, A. M.; GOU, Y.; ROBERTS, J.; BARRETT, K.; FERREIRA, L. G.; SHIMBO, J. Z.; ALENCAR, A.; BUSTAMANTE, M.; WOODHOUSE, I. H.; SANO, E. E.; OMETTO, J. P.; TANSEY, K.; BALZTER, H. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach. *Remote Sensing*, v. 12, n. 17, 2020.
- BUSTAMANTE, M. M. C.; NARDOTO, G. B.; PINTO, A. S.; RESENDE, J. C. F.; TAKAHASHI, F. S. C.; VIEIRA, L. C. G. Potential impacts of climate change on biogeochemical functioning of cerrado ecosystems. *Brazilian Journal of Biology*, v. 72, n. 3, p. 655–671, 2012.
- CHANG, J.; SHOSHANY, M. Radar polarization and ecological pattern properties across Mediterranean-to-arid transition zone. *Remote Sensing of Environment*, v. 200, n. 08, p. 368–377, 2017.
- CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric radar vegetation index for biomass estimation in desert fringe ecosystems. *IEEE Transactions on Geoscience and Remote Sensing*, v. 56, n. 12, p. 7102–7108, 2018.

- CHARBONNEAU, F.; TRUDEL, M.; FERNANDES, R. Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping. In: *Proceedings of the 2005 Advanced Synthetic Aperture Radar (ASAR) Workshop*. St-Hubert, QC, Canada: [s.n.], 2005. p. 15–17.
- CLOUDE, S.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, v. 35, n. 1, p. 68–78, 1997.
- FREEMAN, A.; DURDEN, S. A three-component scattering model for polarimetric sar data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 36, n. 3, p. 963–973, 1998.
- FRISON, P.-L.; FRUNEAU, B.; KMIHA, S.; SOUDANI, K.; DUFRÊNE, E.; TOAN, T. L.; KOLECK, T.; VILLARD, L.; MOUGIN, E.; RUDANT, J.-P. Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. *Remote Sensing*, v. 10, n. 12, p. 10, 2018.
- HARFENMEISTER, K.; ITZEROTT, S.; WELTZIEN, C.; SPENGLER, D. Agricultural monitorins using polarimetric decomposition parameters of sentinel-1 data. *Remote Sensing*, v. 13, n. 575, p. 28, 2021.
- HARFENMEISTER, K.; SPENGLER, D.; WELTZIEN, C. Analyzing Temporal and Spatial Characteristics of Crop Parameters Using Sentinel-1 Backscatter Data. *Remote Sensing*, v. 11, n. 13, 2019.
- JI, K.; WU, Y. Scattering Mechanism Extraction by a Modified Cloude-Pottier Decomposition for Dual Polarization SAR. *Remote Sensing*, v. 7, n. 6, p. 7447–7470, 2015.
- JOLY, C.; PADGURSCHI, C.; PIRES, A. A. A.; MARQUES, A.; AMARAL, A.; CERVONE, C.; ADAMS, C. C.; BACCARO, F.; SPAROVEK, G.; OVERBECK, G.; ESPINDOLA, G.; VIEIRA, I.; METZGER, J.; SABINO, J.; FARINACI, J.; QUEIROZ, L.; GOMES, L.; CUNHA, M.; PIEDADE, M.; BUSTAMANTE, M.; MAY, P.; FEARNSIDE, P.; PRADO, R.; LOYOLA, R. *Apresentando o diagnóstico brasileiro de biodiversidade e serviços ecossistêmicos*. São Carlos, Brazil: Editora Cubo, 2019.
- KELLNDORFER, J. Sar methods for mapping and monitoring forest biomass. In: FLORES-ANDERSON K. E. HERNDON, R. B. T. A. I.; CHERRINGTON, E. (Ed.). *Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. Huntsville: NASA, 2019. cap. 3, p. 65–171.
- KIM, Y.; JACKSON, T.; BINDLISH, R.; LEE, H.; HONG, S. Radar vegetation index for estimating the vegetation water content of rice and soybean. *IEEE Geoscience and Remote Sensing Letters*, v. 9, n. 4, p. 564–568, 2012.
- KIM, Y.; Van Zyl, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 8, p. 2519–2527, 2009.

- KIM, Y.; ZYL, J. van. Comparison of forest parameter estimation techniques using sar data. In: *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium* (Cat. No.01CH37217). [S.l.: s.n.], 2001. v. 3, p. 1395–1397 vol.3.
- KLINK, C. A.; MACHADO, R. B. Conservation of the brazilian cerrado. *Conservation Biology*, v. 19, n. 3, p. 707–713, 2005.
- LEWIS, K.; BARROS, F. V. de; CURE, M. B.; DAVIES, C. A.; FURTADO, M. N.; HILL, T. C.; HIROTA, M.; MARTINS, D. L.; MAZZOCHINI, G. G.; MITCHARD, E. T. A.; MUNHOZ, C. B. R.; OLIVEIRA, R. S.; SAMPAIO, A.; SARAIVA, N. A.; SCHMIDT, I. B.; ROWLAND, L. Beyond trees: Mapping total aboveground biomass density in the brazilian savanna using high-density uav-lidar data. *Scientific Reports*, v. 12, n. 1588, p. 17, 2021.
- MANDAL, D.; KUMAR, V.; RATHA, D.; DEY, S.; BHATTACHARYA, A.; LOPEZ-SANCHEZ, J. M.; MCNAIRN, H.; RAO, Y. S. Dual polarimetric radar vegetation index for crop growth monitoring using sentinel-1 sar data. *Remote Sensing of Environment*, v. 247, p. 111954, 2020.
- MENDES, F. d. S.; BARON, D.; GEROLD, G.; LIESENBERG, V.; ERASMI, S. Optical and SAR remote sensing synergism for mapping vegetation types in the endangered Cerrado/Amazon ecotone of Nova Mutum-Mato Grosso. *Remote Sensing*, v. 11, n. 10, 2019.
- MITTERMEIER, R.; GIL, P.; HOFFMANN, M.; PILGRIM, J.; BROOKS, T.; MITTERMEIER, C.; LAMOREUX, J.; FONSECA, G. D. *Hotspots Revisited: Earth's Biologically Richest and Most Endangered Terrestrial Ecoregions: Conservation International*. Sierra Madre, Cemex: University of Chicago Press, 2005.
- NASIRZADEHDIJAZI, R.; SANLI, F. B.; ABDIKAN, S.; CAKIR, Z.; SEKERTEKIN, A.; USTUNER, M. Sensitivity analysis of multi-temporal Sentinel-1 SAR parameters to crop height and canopy coverage. *Applied Sciences*, v. 665, n. 9, p. 7581–7609, 2019.
- NASIRZADEHDIJAZI, R.; SANLI, F. B.; ABDIKAN, S.; CAKIR, Z.; SEKERTEKIN, A.; USTUNER, M. Sensitivity analysis of multi-temporal Sentinel-1 SAR parameters to crop height and canopy coverage. *Applied Sciences*, v. 9, n. 4, 2019.
- NIZALAPUR, C. S. J. V.; MADUGUNDU, R. Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. *International Journal of Geomatics and Geosciences*, v. 1, n. 2, p. 167–178, 2010.
- PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. *Remote Sensing of Environment*, n. 217, p. 537–549, 2018.
- QUEGAN, S.; TOAN, T. L.; YU, J. J.; RIBBLES, F.; FLOURY, N. Multitemporal ers sar analysis applied to forest mapping. *IEEE Transactions On Geoscience and Remote Sensing*, v. 38, n. 2, p. 741–753, 2000.

- RANEY, K. R.; CAHILL, J. T.; Patterson Wesley, G.; BUSSEY, D. B. J. The m-chi decomposition of hybrid dual-polarimetric radar data with application to lunar craters. *Journal of Geophysical Research E: Planets*, v. 117, n. 5, p. 1–8, 2012.
- SAATCHI, S. SAR Methods for Mapping and Monitoring Forest Biomass. In: FLORES-ANDERSON K. E. HERNDON, R. B. T. A. I.; CHERRINGTON, E. (Ed.). *Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. Huntsville: NASA, 2019. cap. 5, p. 207–253.
- SANO, E. E.; FERREIRA, L. G.; HUETE, A. F. Synthetic Aperture Radar (L band) and Optical Vegetation Indices for Discriminating the Brazilian Savanna Physiognomies: A Comparative Analysis. *Earth Interactions*, v. 9, p. 15, 2005.
- SANO, E. E.; PINHEIRO, G. G.; MENEZES, P. R. Assessing JERS-1 synthetic aperture data for vegetation mapping in the Brazilian Savanna. *Journal of The Remote Sensing Society of Japan*, v. 21, n. 2, p. 158–167, 2001.
- SANO, E. E.; RIZZOLI, P.; KOYAMA, C. N.; WATANABE, M.; ADAMI, M.; SHIMABUKURO, Y. E.; BAYMA, G.; FREITAS, D. M. Comparative analysis of the global forest/non-forest maps derived from sar and optical sensors. case studies from brazilian amazon and cerrado biomes. *Remote Sensing*, v. 13, n. 3, 2021.
- SANO, E. E.; ROSA, R.; SCARAMUZZA, C. A. d. M.; ADAMI, M.; BOLFE, E. L.; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; MAURANO, L. E. P.; NARVAES, I. d. S.; FILHO, F. J. B. d. O.; SILVA, E. B. d.; VICTORIA, D. d. C.; FERREIRA, L. G.; BRITO, J. L. S.; BAYMA, A. P.; OLIVEIRA, G. H. d.; BAYMA-SILVA, G. Land use dynamics in the Brazilian Cerrado in the period from 2002 to 2013. *Pesquisa Agropecuária Brasileira*, v. 54, n. e00138, p. 5, 2019.
- SANTOS, E. P. dos; SILVA, D. D. da; AMARAL, C. H. do. Vegetation cover monitoring in tropical regions using SAR-C dual-polarization index: seasonal and spatial influences. *International Journal of Remote Sensing*, v. 42, n. 19, p. 7581–7609, 2021.
- SARMIENTO, G.; MONASTERIO, M. Life forms and phenology. In: BOURLIERE, F. (Ed.). *Ecosystems of the Worlds XIII*. Amsterdam, The Netherlands: Elsevier, 1983. cap. 5, p. 79–108.
- SILVA, L. da Rocha da; SANO, E. E. Análise das imagens do satélite RapidEye para discriminação da cobertura vegetal do bioma Cerrado. *Revista Brasileira de Cartografia*, v. 7, n. 68, p. 1269–1283, 2016.
- SPERA, S. A.; GALFORD, G. L.; COE, M. T.; MACEDO, M. N.; MUSTARD, J. F. Land-use change affects water recycling in brasil's last agricultural frontier. *Global Change Biology*, v. 22, n. 10, p. 3405–3413, 2016.
- STRASSBURG, B. B. N.; BROOKS, T.; FELTRAN-BARBIERI, R.; IRIBARREM, A.; CROUZEILLES, R.; LOYOLA, R.; LATAWIEC, A. E.; FILHO, F. J. B. O.; SCARAMUZZA, C. A. de M.; SCARANO, F. R.; SOARES-FILHO, B.; BALMFORD, A. Moment of truth for the cerrado hotspot. *Nature Ecology Evolution*, v. 54, n. 0099, 2017.

SZIGARSKI, C.; JAGDHUBER, T.; BAUR, M.; THIEL, C.; PARRENS, M.; WIGNERON, J.-P.; PILES, M.; ENTEKHABI, D. Analysis of the Radar Vegetation Index and Potential Improvements. *Remote Sensing*, v. 10, n. 1776, p. 15, 2018.

TRUDEL, M.; CHARBONNEAU, F.; LECONTE, R. Using RADARSAT-2 polarimetric and ENVISAT-ASAR dual-polarization data for estimating soil moisture over agricultural fields. *Canadian Journal of Remote Sensing*, v. 38, n. 4, p. 514–527, 2012.

WEIß, T.; RAMSAUER, T.; JAGDHUBER, T.; LöW, A.; MARZAHN, P. Sentinel-1 Backscatter Analysis and Radiative Transfer Modeling of Dense Winter Wheat Time Series. *Remote Sensing*, v. 13, n. 12, p. 25, 2021.

YADAV, V. P.; PRASAD, R.; BALA, R.; SRIVASTAVA, P. K.; VANAMA, V. S. Appraisal of dual polarimetric radar vegetation index in first order microwave scattering algorithm using sentinel-1a (c - band) and alos - 2 (l - band) sar data. *Geocarto International*, v. 0, n. 0, p. 1–19, 2021.

YAMAGUCHI, Y.; MORIYAMA, T.; ISHIDO, M.; YAMADA, H. Four-component scattering model for polarimetric sar image decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, v. 43, n. 8, p. 1699–1706, 2005.

ZIMBRES, B.; RODRÍGUEZ-VEIGA, P.; SHIMBO, J. Z.; da Conceição Bispo, P.; BALZTER, H.; BUSTAMANTE, M.; ROITMAN, I.; HAIDAR, R.; MIRANDA, S.; GOMES, L.; Alvim Carvalho, F.; LENZA, E.; MARACAHIPES-SANTOS, L.; ABADIA, A. C.; do Prado Júnior, J. A.; Mendonça Machado, E. L.; Dias Gonzaga, A. P.; de Castro Nunes Santos Terra, M.; de Mello, J. M.; Soares Scolforo, J. R.; Rodrigues Pinto, J. R.; ALENCAR, A. Mapping the stock and spatial distribution of aboveground woody biomass in the native vegetation of the Brazilian Cerrado biome. *Forest Ecology and Management*, v. 499, n. 10, 2021.

ZYL, J. van. Unsupervised classification of scattering behavior using radar polarimetry data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 27, n. 1, p. 36–45, 1989.