



Aplicação de dados Sentinel 1 e 2 via *Machine Learning* para Mapeamento do Uso e Cobertura da Terra na Área de Proteção Ambiental do Ibirapuitã, Bioma Pampa utilizando o algoritmo de classificação Random Forest

Marcus Vinicius Maidana de Andrade¹, Ulisses Silva Guimarães², Tatiana Mora Kuplich³, Igor da Silva Narvaes⁴

¹Mestrando pelo Programa de Pós-Graduação em Desastres Naturais (PPGDN), Universidade Federal de Santa Catarina (UFSC), vinicius.maidana@acad.ufsc.br (autor correspondente). ²Dr. em Ciências Cartográficas pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP), analista em Ciência e Tecnologia - Sensoriamento Remoto do Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), ulisses.guimaraes@sipam.gov.br. ³PhD. pela School of Geography da University of Southampton na Inglaterra, Tecnologista Sênior no Instituto Nacional de Pesquisas Espaciais (INPE), tatiana.kuplich@inpe.br. ⁴Dr. em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais (INPE), pesquisador Titular III no Instituto Nacional de Pesquisas Espaciais (INPE), igor.narvaes@inpe.br.

Artigo recebido em 02/12/2023 e aceito em 31/05/2024

RESUMO

A abordagem conjunta de imagens de sensores ópticos e de radar de abertura sintética (SAR) tem sido eficaz no mapeamento da cobertura terrestre. Neste trabalho, realizado na área de proteção ambiental do Ibirapuitã, foram empregadas técnicas de machine learning para classificar o uso e a cobertura da terra. O algoritmo Random Forest (RF) foi utilizado a partir dos atributos estatísticos dos produtos derivados de imagens ópticas Sentinel-2, como o Índice de Vegetação de Diferença Normalizada (NDVI), o Índice de Água-Diferença Normalizada (NDWI) e o Índice de Vegetação-Ajustado ao Solo (SAVI), além de atributos provenientes de imagens SAR Sentinel-1, como coeficiente de retroespalhamento, parâmetros polarimétricos e interferométricos. Os resultados mostraram que o classificador RF foi robusto, com valores médios de Exatidão Global, Coeficiente Kappa e F1-Score de 96,89%, 0,9495 e 0,8909, respectivamente. A combinação de atributos SAR e dados ópticos permitiu uma melhor discriminação para algumas classes, como área urbana, área úmida e agricultura. A metodologia proposta alcançou alta acurácia e precisão na classificação de uso e cobertura da terra, exceto no uso isolado dos dados Sentinel-1. Como destaque, tem-se a introdução da coerência interferométrica que resultou no melhor resultado entre os cenários propostos.

Palavras-chave: Sinergia Sentinel 1 e 2. *Random forest*. *Machine learning*. Bioma Pampa.

Application of Sentinel-1 and Sentinel-2 data via Machine Learning for Land Use and Land Cover Mapping in the Ibirapuitã Environmental Protection Area, Pampa Biome, using the Random Forest Classification Algorithm

ABSTRACT

The joint approach of optical sensor images and synthetic aperture radar (SAR) has been effective in land cover mapping. In this study, conducted in the Ibirapuitã environmental protection area, machine learning techniques were employed to classify land use and cover. The Random Forest (RF) algorithm was applied using statistical attributes from Sentinel-2 optical image products, such as Normalized Difference Vegetation Index (NDVI), Normalized Difference Water Index (NDWI), and Soil-Adjusted Vegetation Index (SAVI), along addition to attributes from images Sentinel-1 SAR images, including backscattering coefficient, polarimetric parameters, and interferometric data. The results demonstrated the robustness of the RF classifier, with average values of Overall Accuracy, Kappa Coefficient, and F1-Score reaching 96.89%, 0.9495, and 0.8909, respectively. The combination of SAR attributes and optical data allowed for better discrimination in certain classes, such as urban areas, wetlands, and agriculture. The proposed methodology achieved high accuracy and precision in land use and cover classification, except when using isolated Sentinel-1 data. Notably, the inclusion of interferometric coherence resulted in the best performance among the proposed scenarios.

Keywords: Sentinel-1 and 2 synergy. *Random Forest*. *Machine Learning*. Pampa Biome.

Introdução

O Bioma Pampa, situado por completo no estado do Rio Grande do Sul, ocupa 63% de sua área total e 2,07% do território brasileiro. Reconhecido como um importante tesouro natural, genético e cultural de alcance global em sua variedade de flora nas regiões do Brasil e Uruguai, juntamente com estratégias de preservação e uso (MMA, 2010; Roesch et al., 2009; Rivas et al., 2023). Contudo, o Bioma Pampa é considerado o mais vulnerável à conservação no Brasil, tendo como fator agravante para esse cenário, a sua sustentabilidade em pastagens nativas (Overbeck et al., 2015; (Robert et al., 2024).

Há 49 unidades de conservação (UCs) para o bioma pampa que representam apenas 3,03% das áreas do bioma, ao comparar com o resto do território brasileiro as áreas protegidas correspondem a 18%. Em específico ao Pampa, o percentual protegido do bioma é o menor no Sistema Nacional de Unidades de Conservação (SNUC) em comparação aos demais biomas, e é considerado insuficiente, sendo que o mínimo estabelecido para a conservação em pelo menos 10% do território (MMA, 2014). Ao se considerar a contribuição de UC no Pampa em relação aos demais biomas brasileiros, há apenas 0,96% em relação ao total de Áreas Protegidas em nível nacional (Brentano et al., 2015).

Dada a importância e a vulnerabilidade do bioma Pampa é imprescindível o monitoramento por meio de sensoriamento remoto. Há diversas iniciativas correntes neste sentido como exemplo a avaliação do armazenamento de CO₂ (Chen et al., 2019) com a utilização de uma ampla gama de sensores ópticos e de drone alcançando acurácia na ordem de 90%, de estimativa de biomassa (Qasim et al., 2023; Guerini Filho et al., 2020), respectivamente com valores de erro médio quadrático variando de 51,63 Mg ha⁻¹ em região de floresta subtropical perene de folhas largas utilizando imagens dos sensores Sentinel 1 (S1) e Sentinel 2 (S2) e somente com dados do S2 em áreas de campo nativo no bioma pampa com valores de coeficiente de determinação variando de 0,50 a 0,65 e de uso e cobertura da terra (Trindade et al., 2021; Caballero et al., 2023), utilizando imagens do Landsat OLI e TIRS com bandas do visível e infravermelho-próximo e do termal e classificador orientado a objetos tendo obtido 86% de acurácia global e também na análise de dados da série Landsat com acurácia de 87,4%,

respectivamente, estes últimos tendo como premissa estabelecer uma metodologia robusta para servir de base para o estabelecimento de formas de monitoramento em áreas de grande extensão territorial, de maneira contínua (Baeza et al., 2022; Biao et al., 2021).

Nesta perspectiva, o aumento de publicações utilizando sensoriamento remoto, dos 166 artigos publicados sobre esta temática em sistemas de pastagens, o primeiro publicado sobre os pampas foi em 1995, enquanto pesquisas sobre esse tema vêm acontecendo desde 1985 no resto do mundo, com um aumento expressivo de publicações de acordo com Rocha et al. (2023) à partir de 2010, sobretudo em revistas internacionais com alto fator de impacto.

Há ainda outros estudos com vistas à classificação de uso e cobertura da terra (LULC), e que possuem relevância nas avaliações de dinâmicas ambientais, bem como no entendimento de fenômenos na superfície terrestre somente podendo ser identificados por meio de séries multitemporais. Dados do Sensoriamento Remoto orbital como, imagens multiespectrais e de micro-ondas, respectivamente, de sensores ópticos e de Radar de Abertura Sintética (*Synthetic Aperture Radar-SAR*), permitem maior cobertura, detalhamento espacial e revisita da superfície terrestre em escalas continentais e globais.

Há exemplos promissores desses mapeamentos como os programas: *WorldCover* da Agência Espacial Europeia (ESA), que possui cobertura em escala global para 11 tipos de classes a partir de dados Sentinel-1 e Sentinel-2; *CORINE Land Cover* (CLC) da Comissão Europeia, que disponibiliza geoinformação oriunda de séries Landsat e SPOT; Mapbiomas Brasil, organização constituída por ONGs, universidades e startups tecnológicas, que realizam o mapeamento anual do território brasileiro, discriminando um total de 27 classes (Copernicus, 2023).

Inicialmente o Programa de Monitoramento do Desmatamento na Amazônia (PRODES) conduzido pelo Instituto Nacional de Pesquisas Espaciais (INPE) era a principal fonte de informação sobre o desmatamento somente na Amazônia. Com o advento do Programa BiomasBR, o qual monitora todos os biomas brasileiros, em paralelo o monitoramento contínuo da supressão da vegetação nativa no bioma Pampa, realizado desde 2001 pelo INPE, sendo que desde 2019 pela sua Coordenação Espacial do Sul (COESU), denominado de PRODESPampa realiza

o monitoramento contínuo e pesquisas com foco no aprendizado, modernização e automatização dos métodos de interpretação e mapeamento da supressão da vegetação nativa (Kuplich et al., 2023) utilizando inteligência artificial (IA).

O desenvolvimento de novas metodologias voltadas a detecção de mudanças do LULC se mostra em ascensão com muitas técnicas disponíveis e de alta performance dos classificadores baseados em inteligência artificial, exemplos destes são os algoritmos de classificação baseados em técnicas de *Machine Learning* (ML) e *Deep Learning* (DL), como *Random Forest* (RF), *Support Vector Machine* (SVM), *Classification and Regression Trees* (CART), U-net, SF-net e *Long Short-Term Memory* (LSTM) (Arveti et al., 2016; Mamun et al., 2013).

Os classificadores de ML e DL são capazes de atingir precisões de F-score em média melhores que 0,97 para dados fusionados, 0,95 para dados ópticos e 0,90 para dados SAR, desempenho ainda na maioria das pesquisas geralmente ocorrentes em experimentos locais resultando em uma abrangência restrita (Foody, 2002; Ghimire, 2012; Nery, 2016; Raczko e Zagajewski et al., 2017; Ghorbanian et al., 2022; Aduagna et al., 2022).

Assim, as alternativas abordadas nos estudos mais recentes em LULC via ML (Khalil et al., 2018; Zeferino et al., 2020; Andrade et al., 2021), demonstram um promissor potencial na aplicação de mapeamento de classes contidas em regiões diversas do bioma Pampa, tendo em vista melhorias dos resultados advindos da união de dados ópticos e SAR, sobretudo pela incorporação dos dados SAR, ao contribuir significativamente na dissimilaridade de classes complexas e no ganho de performance na acurácia do mapeamento de LULC utilizando produtos Single Look Complex (SLC), no mapeamento de classes sujeitas à variáveis ambientais diversas como sazonalidade, conteúdo de umidade e características da paisagem e relevo (Zakeri et al., 2017; Guimarães et al., 2020; Erinjery et al., 2018; Joshi et al., 2016; Torbick et al., 2017; Whyte et al., 2018), sendo que nestes casos os desafios estão em adquirir e validar massivas quantidades de amostras, e ainda, em generalizar os modelos de ML e DL para grandes e complexas paisagens como o bioma Pampa.

Os produtos provenientes de sistemas SAR, vêm favorecendo as pesquisas voltadas a discriminação das diferentes classes dispostas na superfície terrestre, isto devido à redução de efeitos diretos da atmosfera nesses dados e por conta de

sua capacidade de reduzir substancialmente as interferências por cobertura de nuvens e pela presença do ruído speckle, embora este possa ser minimizado, e quando combinados com dados ópticos produzir altos valores de acurácia (Niculescu et al., 2018) superiores aos gerados apenas com sensor SPOT-6, também corroborados por Zhang et al. (2019) e Guimarães et al. (2020) os quais obtiveram valores de acurácia superiores ao incorporar variáveis SAR do S1 aos dados ópticos com técnicas de classificação baseadas em ML.

As tentativas recentes de monitoramento em escala global de LULC utilizam majoritariamente classificadores de ML e DL, os quais têm restrições em função da disponibilidade de dados orbitais e sua periodicidade de atualização. Em adição, há problemas como escassez de dados *in situ*, em implementar técnicas avançadas tais quais análise multifonte, multitemporal e multinível, dificuldade em alcançar modelos robustos de alta performance, e por estes fatores apresentar escalabilidade para detecção de mudanças (Macarringue et al., 2022; Molinm Rizzoli, 2022; Matosak et al., 2022).

Assim, a hipótese de que o emprego dos produtos provenientes do S1 e S2, tende a proporcionar uma melhoria de performance da classificação se comparado com dados isolados necessita ser testada no bioma pampa pelo pequeno número de investigações em larga escala e pelas características distintas da vegetação e dos usos em relação aos demais biomas de acordo com nossa linha investigativa proposta.

Neste contexto, o objetivo da presente pesquisa foi avaliar o desempenho de diferentes produtos extraídos da sinergia S1 e S2 na classificação de uso e cobertura da terra utilizando metodologia de ML com o algoritmo RF, e de informações estatísticas extraídas das imagens de sensores ópticos como forma de estabelecer uma metodologia robusta capaz de servir como base para o monitoramento contínuo do bioma pampa em desenvolvimento pelo INPE.

Materiais e métodos

Área de Estudo

O estudo foi desenvolvido na Área de Proteção Ambiental (APA) do Ibirapuitã e arredores, definida por uma Unidade de Conservação (UC) situada nas coordenadas

geográficas 29°44'30" S 53°46'30" O e 29°42'30" S 53°45'00" O. A APA está situada na região sudoeste do Estado do Rio Grande do Sul e abrange em parte quatro municípios: Alegrete, Quaraí, Rosário do Sul e Santana do Livramento, com área de 3.167,88 km². Além disto, foi efetuado a criação de um *buffer* de 15 km além do limite original,

sendo denominado como zona de amortecimento devido à pressão antrópica nos seus arredores, totalizando uma área total para a pesquisa de 6.045,34 km² (Figura 1). Nessa área, na parte centro-norte ocorrem extensas áreas de florestas aluviais, além da predominância de florestas de galeria e Savana Estépica gramíneo-lenhosa.




Figura 1 - Mapa de localização da área de estudo.

Dados Orbitais e softwares utilizados

Os produtos utilizados foram quatro imagens Sentinel-1B correspondentes às datas 02/01/2021 e 14/01/2021, no modo *Interferometric Wide Swath* (IW), com largura de imageamento de 250 km e resolução geométrica de 20 x 5m e modo *Single Look Complex* (SLC) este último além do dado em amplitude com a preservação da fase e três cenas do sensor óptico *Instrument Multispectral Imager* (MSI) à bordo do Sentinel-2B, datadas de 02/02/2022 e 14/02/2022, com 10 m de resolução espacial, tendo sido descartadas as bandas 1 Aerossol – 60 m de resolução espacial e a banda 10 Cirrus - 60 m. O download das imagens Sentinel 1 e 2, foi feito na plataforma do programa Copernicus de observação da Terra da União Européia, disponível gratuitamente em (<https://scihub.copernicus.eu/dhus/#/home>).

Ainda, para realizar a ortorretificação dos dados SAR, foram baixadas quatro cenas do Modelo Digital de Elevação (MDE) ALOS PALSAR, disponibilizadas com resolução espacial de 12,5 m, adquiridas através do portal Earth Data (<https://search.asf.alaska.edu/#/>) da Administração Nacional da Aeronáutica e Espaço (NASA).

Ambos os tipos de imagens foram executados no SNAP e o processo de segmentação, treinamento dos modelos de classificação e obtenção das informações relativas às diferentes classes da área de estudo, foi adotado o plugin Orfeu ToolBox (OTB) versão 6.1. Para a extração dos atributos estatísticos das imagens e determinação de amostras, foi escolhido o SIG QGIS Desktop, versão 3.22.7. Ainda, para melhor interpretação do terreno durante a aquisição de amostras de treinamento e validação e conferência

de dúvidas quanto às classes, foi acessado o plugin Planet Explorer, sob licença do Censipam por meio instalação no ambiente SIG para o QGIS (Rede Mais/MJSP, 2023).

Metodologia

O processamento das imagens obedeceu às seguintes etapas: (i) pré-processamento e integração dos produtos; (ii) segmentação e extração de atributos estatísticos e; (iii) classificação e validação (Figura 2).




Figura 2 – Cadeia de processamento gerada.

Processamento Sentinel – 1

Duas aplicações iniciais foram realizadas no conjunto de imagens: Primeiro se realizou a combinação de faixas entre as imagens, mantendo os mesmos parâmetros do produto, consequentemente reduzindo a necessidade de repetição dos processos em dados de mesma faixa

imageada, conforme a área de interesse (*Slice Assembly*) e; a atualização automática dos vetores de estado da órbita que compõem os metadados dos produtos SAR indicando a posição precisa do satélite e sua velocidade (*Apply Orb File*) de acordo com o estabelecido por Filipponi et al. (2019).

Dos produtos SAR foram obtidos os seguintes produtos:

- Coeficiente de retroespalhamento (*backscattering*) (Carreiras et al. 2017; Filipponi, 2019).

Efetuiu-se a remoção do ruído térmico da imagem (*Thermal Noise Removal*), que corrige o ruído termal presente entre as sub-faixas e reduz a descontinuidade entre elas; a calibração em beta zero (β^0) (Calibrate) (Eq 1); a normalização radiométrica em gamma zero (γ^0) (*Radiometric Terrain Flattening*), visando minimizar a dependência angular incidente do retroespalhamento do radar (Small, 2011) (Eq 2) e para amenizar o efeito *speckle* foi utilizado o filtro Lee com janela 9x9 (Lee, 1980).

$$\beta^0 = \beta / A_\beta \quad (1)$$

onde $\beta = P_s / P_i$, sendo: P_s (razão da energia espalhada); P_i (energia incidente); A_β refere-se a área de referência (retângulo sólido, que se baseia no plano de alcance inclinado).

$$\gamma_E^0 = \beta^0 \cdot \frac{A_\beta}{A_\gamma} = \beta^0 \cdot \tan \theta_E \quad (2)$$

- Decomposição polarimétrica de Cloude e Pottier Dual (H-Alfa) (Plank et al., 2017; Shuai et al., 2019).

Foi gerada uma imagem contínua em azimuth removendo a separação de linhas escuras e sobreposição entre subfaixas da imagem (*deburst*); função de reamostragem com janela de pixel (x e y) aplicada para a geração da resolução espacial da imagem (*multilooking*, filtragem para preservar as informações complexas (fase) e reduzir a presença do ruído *speckle* (*Polarimetric Speckle Filter*), utilizando o filtro polarimétrico Refined-Lee com uma janela de 5x5 (Lee, 1981; Pôssa et al., 2018);

Foram geradas as informações de decomposição polarimétrica e seu respectivo significado físico (Decomposition H-Alpha) com entropia - H (mede a aleatoriedade) e ângulo alfa (α) que descreve as características dos mecanismos de espalhamento (Cloude; Pottier, 1997) e; por fim realizada a correção de distorções geométricas causada pela topografia, como *layover*, *foreshortening* e sombra, usando um modelo digital de elevação para corrigir a localização de cada pixel (Range-Doppler Terrain Correction Operator).

- Coerência interferométrica (Miguel e Sano, 2019).

A coerência ($Y_{VV} - Y_{VH}$) interferométrica indica o nível de similaridade em relação às fases de ambos os sinais de retorno pertencentes a um dado sistema InSAR. Essa grandeza, normalmente é abordada em pesquisas relativas à caracterização da cobertura vegetal, por conta de seus padrões volumétricos temporais (Diniz et al., 2019; Mohammadimanesh et al., 2018), indicando a similaridade de determinadas feições ou a diferença entre datas distintas.

Para tal, foi realizada a seleção da uma subárea de interesse, com o objetivo de atenuar a demanda computacional (*Split*), tendo as imagens um intervalo de 12 dias em relação a sua data de obtenção (Miguel e Sano, 2019; Diniz et al., 2019); o georreferenciamento das informações de amplitude e fase (*Coregistration/S-1 Back Geocoding*), de modo que os pixels de ambas imagens sejam coincidentes, procedimento baseado na técnica de correlação cruzada na obtenção da acurácia do sub-pixel, que resultou em uma imagem apta a computar a coerência interferométrica.

Para estimar os deslocamentos em *range* e azimuth oriundos do georreferenciamento, foi utilizado o recurso *Enhance Spectral Diversity*; e aplicado o *Deburst* na imagem e; posteriormente executou-se a fusão das faixas de visada IW1 e IW2 (*Merge*). Posteriormente, deu-se origem à imagem coerência (*Coherence*), com uma janela 10 x 3, seguindo a recomendação de Diniz et al. (2019).

Ao final, foram aplicadas as ferramentas *Multilooking* e *Range-Doppler Terrain Correction Operator*. A coerência interferométrica entre duas imagens SAR é definida na Equação 3, onde: γ se refere à coerência interferométrica; S_1 e S_2 são as duas imagens complexas co-registradas e $\langle \rangle$ é a média em relação ao tamanho da janela.

$$\gamma = \frac{|\langle S_1(x) S_2^*(x) \rangle|}{\sqrt{\langle |S_1(x)|^2 \rangle \langle |S_2(x)|^2 \rangle}} \quad (3)$$

Processamento do Sentinel-2

Para a imagem S-2, inicialmente foi realizado o procedimento de correção atmosférica proposto por Pompêo (2019), utilizando a ferramenta Sentinel-2 Atmospheric Correction (Sen2Cor), presente no SNAP. Feito isso, foram gerados três índices radiométricos normalizados:

3719

Índice de Vegetação de Diferença Normalizada - NDVI (Rouse et al., 1974), Índice de Vegetação Ajustado ao Solo – SAVI (Huete, 1988) e Índice de Água Diferença Normalizada - NDWI (Gao, 1996) índices amplamente utilizados em pesquisas de classificação com *Random forest* no Brasil (Zeferino et al., 2020; Andrade et al., 2021).

Integração das informações

Foram realizados os ajustes em relação ao sistema de projeção e dimensões dos elementos de resolução (SAR e ópticos). Logo, as informações foram reprojatadas e reamostradas, sendo definidas para o sistema de coordenadas planas *Universal Transversa de Mercator* (UTM) Fuso 21 S e Datum WGS84, com resolução espacial de 10m x 10m, mantendo dessa forma a conformidade geométrica em relação aos *pixels* de todos os produtos. Para tal realizou-se o empilhamento dos produtos de forma que os elementos de resolução (*pixels*) coincidiram perfeitamente (*Collocation*).

Foram definidos os produtos derivados de dados S-1, como “mestre” e os produtos S-2 e seus índices derivados, sendo “escravos”. Ao final, foi realizado o recorte da área analisada via *subset* da cena.

Geração dos atributos estatísticos e definição das classes para a classificação no RF

Foi efetuado o recorte da área de estudo dos produtos empilhados e após, segmentada a composição RGB 483 do S-2, com valores dos parâmetros de 15 em *Spatial radius* e 90 para *Range radius*, em formato *shapefile* (polígonos) (Figura 3). Posteriormente foi realizada a extração de 11 parâmetros estatísticos (soma, média, mediana, desvio padrão, mínimo, máximo, intervalo, minoria, maioria, variabilidade e variância), que teve como base as bandas de todos os produtos abordados no estudo (produtos ópticos e SAR).

Com base no histórico de uso e cobertura da terra na área de estudo, foram estipuladas as seguintes classes:

- Campo ralo (CR): área de campo nativo de baixa cobertura de vegetação devido a fatores como seca, alta lotação de gado associados à solos rasos situados em topos de coxilhas a profundos em regiões planas;
- Água (AG) – corpos d’água naturais (lagos e cursos d’água) ou construídos (açudes e

barragens); Floresta (FT): Cobertura florestal com textura alta decorrente da copa de árvores;

- Campo (CP): áreas de campo com cobertura vegetal nativa e quase ausência de campo ralo associadas à solos profundos de encostas de coxilha e em regiões planas com variação de solo raso a profundo;

- Área úmida (AM): áreas naturais e áreas agricultáveis cobertas com lâmina d’água (por ex. plantios de arroz);

- Área urbana (AU): área contínua construída e arruamentos;

- Agricultura (AT): áreas com agricultura implantada (textura, forma e comportamento espectral distinto das áreas de campo)

Treinamento e validação do algoritmo RF

Para determinar as amostras de treinamento e de validação, foram utilizadas 2 composições do satélite S-2: 4 (vermelho – 665 nm) 3 (verde – 560 nm) 2 (490 nm) e 4 (665 nm); 8 (IVP – 842 nm); 3 (560 nm).

No total, foram selecionadas 1354 amostras, das quais foram definidas aleatoriamente 947 (70%) para treinamento e classificação e 407 (30%) destinadas à validação dos resultados.

Para as amostras de validação que mantinham as feições originais da segmentação, foram criados pontos internos nos segmentos, visando aumentar a confiabilidade das estimativas, utilizando a validação cruzada aleatória efetuada a partir de seleção e identificação de classes, mantendo a independência espacial entre os conjuntos amostrais com distribuição não proporcional devido à ocorrência menor de algumas classes na área de estudo, situação recorrente em demais estudos do gênero (Thanh Noi e Kappas, 2017).

A chave de interpretação da Figura 3 ilustra a seleção das classes conforme o limiar de segmentação utilizado. Para a composição de bandas gerada a partir dos produtos SAR destacam-se mecanismos de dispersão oriundos de corpos d’água (reflexão especular em ciano) e construções urbanas (*double bounce* em magenta), que também são ressaltados devido ao produto de coerência interferométrica combinado ao canal vermelho e em azul as áreas predominantemente cobertas de vegetação descritas pelo mecanismo de espalhamento predominante envolvidos na cena (ângulo alfa – α).




Figura 3 – Chave de interpretação.

Algoritmo de classificação Random forest

O algoritmo de classificação RF opera por um processo de prognóstico de resultados que se baseiam em um conjunto de árvores de decisões (Ntree), estipulando parâmetros, como a quantidade de árvores na floresta (*Maximum number of trees in the forest* – Ntree), e a profundidade dessas (*Maximum depth of tree* – Mtry).

Após inúmeros testes, foram estabelecidos como parâmetros do modelo Ntree = 100 e Mtry = 5 já que o parâmetro ótimo pode variar e está relacionado ao tipo de alvo a ser analisado (Nitze et al., 2012).

Para a geração da classificação final, foram utilizados parâmetros estatísticos conforme a combinação de cada árvore, para computar e

normalizar dados de entrada incomensuráveis (Breiman, 2001; Maxwell, 2018), o que permitiu a integração das estatísticas zonais de ordem e magnitude distintas extraídas dos produtos ópticos e SAR.

Com o intuito de melhorar a acurácia dos modelos integrados enquanto reduzem a variância dos dados, foi utilizado o método de aprendizagem em conjunto *bagging* como forma de diminuir a chance de ocorrência do sobreajuste (overfitting), ou seja, a possibilidade de o modelo de aprendizado fornecer previsões precisas para os dados de treinamento, mas não para novos dados na validação (Sheykhoumousa, 2020).

Métricas de validação e escolha da melhor classificação

No processo de validação, foram utilizadas imagens de alta resolução espacial do Satélite Planet (3 metros) disponíveis via complemento *Planet Explorer* do QGIS através de acesso à plataforma do Centro Gestor e Operacional do Sistema de Proteção da Amazônia (Censipam), com imagens com data coincidentes com o Sentinel-2.

A partir das seis matrizes de erro, originadas por cada classificação, foram computadas métricas de validação, como: (i) o Índice Kappa (Landis e Koch, 1977) que estima a confiabilidade dos mapas, considerado referência para a classificação; ii) o Índice de Exatidão Global (Congalton e Green 2019) que descreve a razão entre acertos de pontos classificados e a quantidade total de pontos base; iii) F1 Score métrica de ML amplamente utilizada em abordagens com classificações que utilizam esses algoritmos (Cao et al., 2020; Barbosa et al., 2021), definido pela média harmônica entre o *precision* e o *recall*.

Para melhor analisar o comportamento individual das classificações, foi considerado o percentual de cobertura (em %) de cada classe, o qual destaca as variações de área comparadas uma a uma em relação à melhor classificação a ser escolhida. Este método é baseado na aproximação entre as classes com base no maior F1 score.

Resultados e discussão

Distribuição do *backscattering*

Foram apuradas as informações de intensidade provenientes do *backscattering* em γ^0 para cada classe (Figura 4). Para a separabilidade com base nas polarizações, os valores médios de retorno mais baixos observados, destacam-se na classe AG, sendo de -25,10 dB - VH e -18,57 dB - VV, com intervalo de 6,5 dB entre polarizações. A água (AG) possui alto potencial discriminatório devido suas características de textura suave e baixa intensidade, onde prevalece uma reflexão especular da energia incidente. A discriminação de corpos hídricos e demais classes por meio de imagens, fica mais evidente na polarização VH (Ferreira, 2018; Novo e Costa, 2005).

No entanto, alguns padrões inerentes a esses dados destacam tal classe das demais. O 3º quartil em ambas as polarizações apresentou valores com um intervalo superior, quando comparados ao 1º quartil, o que demonstra uma distribuição assimétrica positiva que também pode ser observada através do distanciamento entre média e mediana. Verificou-se o maior intervalo de dispersão dos dados, bem como uma maior amplitude, que prevalecem na polarização VV.

Esse desequilíbrio pode ter ocorrido devido a ocorrência de elementos contidos nas amostras, como encostas/bordas de açudes ou lagos e, até mesmo a presença de sedimentos superficiais passíveis de interação na banda C. Para as demais classes, as distribuições possuem homogeneidade entre os quartis com variações relevantes.




Figura 4 - Comportamentos de informações de intensidade por classe - AG (Água); AM (Área úmida); AT (Agricultura); AU (Área urbana); CP (Campo); FT (Floresta); CR (Campo ralo).

Separabilidade entre classes

Na análise de separabilidade entre as diferentes classes (Figura 5) parâmetros inferiores a 0,8 são considerados insuficientes para distinguir as classes. Uma separabilidade média entre classes deve apresentar valor entre 0,8 e 1,5, sendo que acima de 2, considera-se um potencial de separação completo (Richards, 1987; Shi et al., 1994).

Nessa análise, não ocorre o potencial de separabilidade total em relação ao *backscattering* estimado em γ^0 , todavia o bom potencial é visto em cinco casos. Para CR/FT, tem-se 1,84 em VH, já em VV esse valor diminui para 1,22, já que a uma maior distinção é ocasionada pelo espalhamento volumétrico na copa das árvores utilizando a polarização cruzada (VH ou HV) neste comprimento de onda (Freeman e Durden, 1998; Schmitt e Brisco, 2013), embora o tipo de floresta possua relevante influência no sinal de retorno (Dostálová et al., 2016).

O potencial de classificação entre áreas florestais e não-florestais por meio de dados em banda C vem sendo evidenciado (Hansen e Mitachard, 2020). Quegan (2000) destaca o potencial do SAR nesse comprimento de onda para detecção de degradação florestal, embora as aplicações florestais utilizando apenas esta frequência não sejam tão populares.

No par AG/FT, para VH o valor estimado é de 1,87, em VV é 1,64, onde a melhor separabilidade na polarização cruzada está relacionada a maior diferença entre os valores de

retroespalhamento (γ^0) na polarização cruzada para alvos florestais, ou seja, valores superiores de (γ^0) relacionados principalmente ao espalhamento volumétrico da floresta (Narvaes et al., 2010) em relação aos valores baixos decorrentes da reflexão especular.

Em AG/AU apresentou uma separabilidade média destas classes na polarização VH (1,56) e em VV de 1,47, discrepância ligeiramente curta entre polarizações da classe de AG, em VH tende a apresentar um sinal de retorno reduzido e mais estável em relação à VV (Novo e Costa, 2005). Contudo, corroborando com o comportamento visto na Figura anterior, possíveis variações nos padrões dos corpos hídricos (classe AG), como a presença de sedimentos, superfície d'água parada ou movimentada ou, açudes com taipas voltadas para a onda incidente do sistema sensor podem ter ocasionado estes valores, visto que o conjunto de amostras que resultou nos valores desta análise não foram determinadas por seleção pontual e sim por segmentos.

Analisando FT/CP, também é possível distinguir essas classes de maneira satisfatória, sendo 1,53 – HV e 1,05 VV, comprovado em estudos de métodos de monitoramento de desmatamento utilizando banda - C (Dascălu et al., 2023).

Um bom potencial de separação entre FT/AM, para VH (1,83) e de 1,12 para VV. Embora áreas úmidas possam ter valores de retroespalhamento maiores do que áreas de corpos

d'água a menor separabilidade em VV é decorrente da maior interação sinal/alvo (maior retroespalhamento) neste comprimento de onda (entre 3,8 – 7,5 cm) com gramíneas de disposição predominantemente vertical, padrão similar ao encontrado por Hardy et al. (2019) para corpos d'água cobertos com vegetação menor do que 20 cm e em Zhang et al. (2022) para a identificação de

espécies de capim relacionados a mudanças na profundidade da superfície da água em áreas úmidas.

As combinações classificadas com médio potencial de separação entre classes totalizaram 7, enquanto as classes inaptas para separação 9 combinações foram encontradas.




Figura 5: Medida de separabilidade - Box-plot do backscattering γ^0 – AG (Água); AM (Área úmida); AT (Agricultura); AU (Área urbana); CP (Campo); FT (Floresta); CR (Campo ralo).

Resultados da classificação

Sentinel 1 (Retroespalhamento; Decomposição de Cloude e Pottier Dual e; Coerência interferométrica): Cenário 1

Em relação à exatidão global estimada, foram encontrados valores de 76,16%, $k = 0,65$ e F1-score de 0,59, sendo possível inferir que os resultados da classificação baseada nestes dados possuem acurácia média, embora não tão elevados quando comparada aos outros cenários desta análise estes resultados apesar de inferiores aos encontrados por McNair et al. (2021), tendo obtido acurácia de 86% especificamente no monitoramento de áreas agrícolas, todavia com classes de menor complexidade estrutural quando comparado a presente análise. Desta forma, como esperado que os erros de comissão e omissão nos resultados da classificação, sendo que o modelo RF forneceu um percentual de erro para as classes AM

(18%), AU (43%), AG (49%), CP (55,4%) e AT (63,2%).

Estes baixos valores de AP, indicam a ocorrência de áreas que deixaram de ser mapeadas pela classe correta, evidenciando a insuficiência dos dados SAR para o classificador RF (Tabela 1; Figura 6).

O valor mais baixo computado é visto para a classificação de áreas úmidas (AM) com erro de 82% de áreas omitidas na classificação, mesma tendência encontrada para a classe área urbana, água e agricultura. A classe de CR nesse caso, resultou em 69,7%, demonstrando um nível alto de interpretação errônea dos pixels existentes no terreno, seguida pela classe de AT (73,6%) e CP (84,2%).

Conforme observado na análise de separabilidade, as classes mencionadas são vistas como insuficientes para discriminação destas

classes, refletidas nos menores valores das métricas de acurácia avaliados.

Tabela 1 Acurácia do Produtor e Acurácia do Usuário (%) dos seis cenários propostos.

Classes	C-1		C-2		C-3		C-4		C-5		C-6	
	AP	AU	AP	AU	AP	AU	AP	AU	AP	AU	AP	AU
CR	93,0	69,7	99,7	94,4	99,7	96,5	99,7	96,5	99,7	96,5	99,7	96,6
AG	49,0	94,4	70,2	95,2	74,2	100,0	89,6	100,0	91,8	100,0	90,0	100,0
FT	94,7	95,2	95,7	93,0	91,5	95,2	95,7	95,3	91,5	96,4	90,8	96,4
CP	55,4	84,2	95,8	94,7	100,0	95,0	98,0	97,4	100,0	95,0	100,0	97,4
AM	18,0	100,0	71,9	100,0	69,9	100,0	75,7	100,0	70,4	100,0	71,2	100,0
AU	43,0	100,0	41,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0
AT	63,2	73,6	42,5	100,0	50,6	100,0	64,9	97,9	48,1	97,6	68,8	97,8
EG (%)	76,16		94,49		96,08		96,74		96,18		96,89	
K	0,6481		0,9131		0,9369		0,9489		0,9388		0,9495	
F1	0,5949		0,7382		0,8354		0,8909		0,8593		0,8865	

AG (Água); AM (Área úmida); AT (Agricultura); AU (Área urbana); CP (Campo); FT (Floresta); CR (Campo ralo); EG (Exatidão Global); K (Índice Kappa); F1 (F1 Score).

Para a classificação com apenas os dados de retroespalhamento, decomposição polarimétrica de Cloude e Pottier Dual e da coerência interferométrica (cenário 1) a confusão na classificação de áreas de campo e de agricultura, comprovada pelos valores similares do retroespalhamento em γ^0 sobretudo para a polarização VV, embora os valores de γ^0 das áreas de agricultura tenha sido ligeiramente superior, bem como sua variação os baixos valores de

acurácia do produtor e usuário refletiram em um cenário de classificação insatisfatório, com menores valores de precisão e acurácia em comparação aos demais cenários classificados. O tipo de cultura presente na área (arroz) e período de aquisição das imagens é um fator candidato a ter induzido tais resultados, considerando que a dinâmica média desta classe e de áreas de campo se assemelham ao encontrado nos estudos de Fiorillo et al. (2020) e de Lobert et al. (2021).




Figura 6 – Resultados da classificação utilizando o algoritmo de classificação random forest para os seis cenários analisados na APA do Ibirapuitã-RS com recorte próximo ao município de Santana do Livramento – RS. As áreas destacadas por polígonos servem de comparativo para a delimitação das classes.

Desta forma, em nossa análise alvos com elementos espalhadores predominantemente verticais em banda-C para a classe agricultura e campo provavelmente sejam responsáveis pela confusão na classificação de ambos os alvos.

Sentinel-2 (Bandas sem índices de vegetação): **Cenário 2**

Neste cenário a classificação produziu resultados de métricas de validação superiores aos dados SAR aplicados isoladamente, com exatidão global de 94,5%, $k = 0,91$ e $F1 - score = 0,74$ com acurácia considerada alta, embora haja um desbalanço entre os valores de precisão e recall, ou seja, a acurácia do produtor mostra resultados significativamente reduzidos em duas classes, sendo as classes AU (41%) e AT (42,5%) apresentado resultado inferior aos valores observados no primeiro cenário para as mesmas classes, demonstrando que para ambas as classes os altos valores de reflectância da superfície encontrados na região do visível e do infravermelho próximo não foram suficientes para discerni-las satisfatoriamente. Gislason et al. (2006) também encontraram limitação semelhante

utilizando somente dados de reflectância para quatro faixas espectrais no visível e no infravermelho próximo do Landsat MSS na distinção de tipos florestais para o algoritmo random forest quando estas classes possuíam resposta espectral muito similar.

Já em Trindade et al. (2023) também no Bioma Pampa a aplicação do algoritmo de classificação Random Forest em uma região de relevo movimentado e de intensa alteração de uso comprovou que a reflectância nesta mesma região do espectro eletromagnético em combinação com um modelo digital de elevação (MDE) produziram os melhores resultados de classificação.

Sentinel – 2 (Bandas e índices de vegetação): **Cenário 3**

Utilizando como parâmetros de entrada os valores de reflectância das bandas do Sentinel-2, os índices de vegetação normalizados NDVI, SAVI e NDWI demonstraram que a inclusão dos índices de vegetação se mostrou preponderante na melhora da acurácia e precisão da classificação, com valores de exatidão global de 96,1%, $k = 0,94$ e $F1 score =$

0,84, refletindo em altos valores de acurácia e a precisão de moderada a alta para esta classificação.

Os valores de F1 score comprovam um desbalanço entre os valores de precisão e recall. A classe de agricultura apresenta o valor mais baixo para a AP (50,6%), seguida pela AM (69,9%) e AG (74,2%), o que caracteriza uma percentagem elevada de erros de omissão. Todavia, percebe-se que para a classificação de áreas urbanas, em comparação com as classificações do Cenário 1 e 2 com valores de AP baixos, foi computada como 100% na atual classificação, o que destaca a maior capacidade de discriminação entre vegetação e áreas urbanas, resultante dos índices normalizados introduzidos no referente modelo, comportamento semelhante ao observado no estudo de Çavur et al. (2019).

Além das bandas do Sentinel-2 utilizadas, os índices de vegetação possuem valores de importância relevantes para a composição do modelo, como também constatado em Valero et al. (2022) onde em sua classificação utilizando o NDVI obteve um efeito maior na diferenciação de Água, Formação Florestal, florestas plantadas, praias e áreas urbanas.

Resultados similares podem ser vistos em Yuhao et al. (2018) que comprovaram que adicionar não apenas imagens multitemporais e variáveis topográficas, mas também variáveis de textura GLCM e variáveis de séries temporais de NDVI alcançaram a maior precisão geral com 89% e coeficiente kappa (κ) de 0,81 e tendo como variáveis mais importantes para o modelo RF de classificação o NDVI obtido durante a estação de verão seguido da banda o infravermelho próximo na mesma estação.

Sinergia entre Sentinel -1 e Sentinel -2 exceto índices de vegetação: Cenário 4

Nesta classificação, conforme os resultados de acurácia e precisão com exatidão global de 96,7%, $k = 0,95$ e F1 score = 0,89 considerados elevados e de alta acurácia, classificação excelente e precisão alta, respectivamente. Os valores menos discrepantes entre a precisão e recall em relação aos cenários anteriores, principalmente em relação a AU sugere a melhoria nas assertivas conforme a inserção da combinação de dados da região do espectro eletromagnético óptico e da região de microondas no modelo.

Todavia para a AP, percentuais menores relativos às classes de AT (64,9%) e AM (75,7%)

indicam ainda erros de omissão consideráveis. De qualquer modo, esses valores são superiores quando comparados às avaliações anteriores, mostrando um melhor potencial da combinação do dado óptico com SAR.

Diversas pesquisas utilizando dados do Sentinel 1 e 2 de forma integrada para a classificação do uso e cobertura da terra também comprovaram ter atingido os melhores resultados com estes parâmetros de entrada para o algoritmo do RF (Dobrinić et al., 2020; Ibrahim, 2022; White et al., 2018). Ainda em nossa análise, a classificação possui alta confiabilidade já que os valores de acurácia para as demais classes são elevados (p.ex: FT = 95,3% e; CR = 96,5%) e por consequência com baixo percentual de classificações associadas a falsos positivos.

Sinergia Sentinel -1 e Sentinel -2 com índices de vegetação, exceto coerência interferométrica: Cenário 5

Com a adição dos índices de vegetação a sinergia S1 e S2, a aplicação do algoritmo RF produziu valores de acurácia e de precisão com exatidão global de 96,18%, $k = 0,94$ e F1 score = 0,86, ou seja, neste cenário a classificação possui alta exatidão com classificação considerada excelente além de indicar um balanço satisfatório entre os valores de precisão e recall, embora duas classes tenham demonstrado baixa AP, sendo AT (48,1%) e AM (70,4%) e por consequência baixa frequência de classificações corretas quando comparadas com os dados de validação e consequente erros de omissão elevados.

Os valores baixos, principalmente em se tratando da classe AT, podem ser consequência da ausência de informações como a coerência interferométrica. De fato, pesquisas anteriores indicam ganhos em estimativas de classes do gênero ao introduzir tais dados aos dados ópticos para classificação utilizando ML (Werner et al., 2014).

Na classificação de área urbana, os valores percentuais se mantiveram acima de 90% em todos os casos, contudo, segundo Barbosa et al. (2021), o mapeamento de classes do gênero com auxílio da coerência interferométrica ainda é pouco explorado e, verifica-se que a partir dessas análises, os resultados têm sido promissores.

Sinergia Sentinel 1 e Sentinel 2 com índices de vegetação: Cenário 6

São esperados os bons resultados de classificação, pois de acordo com Billah et al. (2023), a principal vantagem do uso de dois produtos Sentinel diferentes combinados é o uso do Sentinel-2 para o mapeamento do uso e cobertura da terra e Sentinel-1, principalmente durante períodos de chuva pelas imagens SAR registrarem informações em regiões com nuvens, além de sua interação com os componentes da vegetação.

Esta combinação para o algoritmo de classificação RF gerou resultados de acurácia e precisão com exatidão global de 96,89%, $k = 0,95$ e F1 score de 0,89. Em relação à exatidão global é possível inferir que os resultados da classificação possuem alta acurácia, por consequência em uma classificação considerada excelente e alto equilíbrio entre os valores de precisão e recall.

No que se refere a este cenário destacam-se os menores valores de AP para AT (68,8%) e AM (71,2%), ou seja, ambas as classes têm probabilidade de serem classificadas como tal relativamente baixa. Esta classificação obteve os melhores resultados em comparação às demais para a classe de agricultura e o segundo melhor para o mapeamento de áreas úmidas. Desta forma, os resultados ficam acima de 96% em relação a acurácia do usuário, demonstrando alta confiabilidade para todas as classes.

Costa et al. (2021), demonstraram que a adição de dados polarimétricos às informações de restroespalhamento, refletiram em um aumento de precisão da classificação com SAR, contudo, os ganhos quando avaliados conjuntamente aos dados ópticos, apresentaram baixa relevância.

Todavia, outras pesquisas evidenciaram que a integração dos índices espectrais, pode resultar em baixa significância na contribuição para a classificação ou até mesmo a ausência de melhorias (Chatziantoniou, 2017; Tavares et al.,

2019). Rosa (2018) descreve o pouco ganho de acurácia utilizando índices espectrais oriundos do cálculo entre bandas e ressalta ainda que o RF passa a possuir novos nós para criação da árvore estatística, mas não são obtidas informações novas.

Ademais, a análise de Pavanelli et al. (2018) evidenciou que a quantidade de variáveis utilizadas para gerar um modelo de classificação a partir do RF não irá necessariamente apresentar resultados melhores, entretanto, a combinação dos dados ópticos e SAR pode beneficiar a classificação, tais como o ocorrido no estudo de Fioravante et al. (2021) tendo alcançado acurácia global de 83% com a proposição de dois novos índices espectrais na distinção de tipos florestais e identificação de áreas queimadas, NDCI e BI, respectivamente.

As estimativas da pesquisa em questão se mostram de acordo com resultados vistos em outros estudos (Olesk et al., 2016; Barbosa et al., 2021). Variações em resultados ocorreram em outros trabalhos (Niculescu et al., 2018), onde tanto os índices espectrais quanto o S1, não agregaram melhorias significativas ao serem atribuídos aos dados S2.

Análise do comportamento das classificações (escolha da melhor classificação)

Com base nas variações de área resultante destacadas (Figura 7A) e nos valores de F1 score (Figura 7B) considerou-se o cenário 4 como parâmetro de análise em comparação às demais classificações. Este cenário foi eleito pela sua maior abrangência no espectro eletromagnético por utilizar a combinação de dados ópticos e SAR e aos altos valores das métricas de validação obtidos, como forma de avaliar a aproximação das classes estudadas.




Figura 6 – Variações (A) e aproximação entre as classes mapeadas (B) baseado no cenário de maior F1 score (Cenário 4).

Para tanto, observou-se a existência de proximidade em relação ao percentual de cobertura por todos os grupos de classes, exceto no cenário 1 composta somente pelos dados SAR, que apresentou valores discrepantes para as classes de agricultura e campo nativo, comprovados pelos baixos valores de separabilidade calculados em relação aos valores de retroespalhamento γ^0 , que demonstra os valores próximos das variáveis SAR.

Ao analisar a área classificada como CR, observa-se baixa variação entre os resultados gerais, que vão de 51% no cenário 4 até 58% no primeiro cenário. A ausência dos índices de vegetação no cenário 4, pode ter induzido uma menor parcela classificada como campo ralo, comportamento semelhante ao observado em estudos como o de Rosembach et al. (2005). A baixa diferença de 7% entre a classe, pode ter ocorrido pela presença de dados SAR no cenário 4 quando aplicados nessas superfícies com campo ralo, pois conforme as feições do terreno, o sinal de retorno apresenta valores de intensidade mais elevados.

A classe AG demonstrou variações não significativas entre as classificações, sendo a menor área classificada para a cenário 2 de 0,3% e 0,4% para o cenário 4, diferenças evidenciadas pelos maiores valores de acurácia do usuário e do produtor na classificação utilizando variáveis de reflectância, de retroespalhamento, decomposição dual de Cloude-Pottier e coerência interferométrica, comprovando que a Sinergia dos dados do Sentinel 1 e Sentinel 2 são uma

alternativa para a melhora do mapeamento utilizando técnicas de ML.

A presença de água em alguns elementos superficiais utilizando o NDWI, por exemplo, podem auxiliar na detecção dessas características, especialmente de áreas alagadas com presença de vegetação (Gao, 1996). Estas diferenças em área de mapeamento desta classe comprovadas pelos valores mais elevados de acurácia do produtor e usuário para o cenário 4, indicam que a inserção de variáveis SAR aumenta a eficácia da classificação e por consequência ocorre uma melhor identificação de áreas de corpos d'água, neste caso dado a maior contribuição dos valores das variáveis SAR às variáveis do sensor óptico empregadas na geração da classificação do cenário 4.

No que se refere a classe FT, o menor valor de percentual de cobertura foi de 12,7% no cenário 1, enquanto a maior área estimada apresentou 14,8% no cenário 2, indicando a importância da presença da reflectância na região da borda do vermelho (red edge 705 a 865 nm), infravermelho próximo (846 nm) e infravermelho de ondas curtas (1610 à 2190 nm) nesta classificação.

Estas se constituíram como variáveis significativas na determinação de áreas de floresta, respectivamente por refletirem mais energia luminosa na faixa de 670-760 nm (Hawryło et al., 2018) além de identificar o arranjo celular diferenciado de cada espécie, o que gera uma resposta espectral singular para cada estrutura foliar (Jensen, 2009; Ponzoni et al., 2012). Além disso, compreendem importantes elementos biofísicos e bioquímicos da vegetação, tais como

lignina (Goergen et al., 2021) e celulose (Vicente et al., 2007).

Ainda para esta classe, o cenário 3 mostra resultados de percentual de cobertura próximos ao cenário 4, embora não tenha obtido os maiores valores de F1 score em comparação à maioria dos demais cenários. Isso evidencia uma melhora na detecção de tal classe a partir da sinergia de informações espectrais, tais como nos estudos de Ibrahim (2022) e Bazzi et al. (2019).

No que se refere a classe CP, tem-se um maior afastamento entre os valores estimados para o cenário 1 de 15,5% de percentual de cobertura com média dos valores distribuídos para as seis classificações de 26,4%, todavia o cenário 4 apresenta 29,9%, valor mais elevado entre as classificações, demonstrando um maior mapeamento das áreas de campo na ausência dos índices de vegetação e diferença em torno 60% à menos de F1 score para esta classe, em comparação a classificação quando utilizado os dados do bandas do Sentinel-2 na região do espectro eletromagnético desde o vermelho, borda do vermelho, infravermelho próximo até o infravermelho de ondas curtas.

Para o estudo de Campos-Taberner et al. (2020) também demonstraram que as bandas do Sentinel-2 do vermelho e do infravermelho próximo transmitiram as informações mais úteis para o classificador de *deep learning* nesta região do espectro capaz de categorizar a vegetação, neste caso as áreas de campo, já que estas duas bandas mapeiam bem as diferenças no índice de área foliar (IAF) e na pigmentação foliar, respectivamente.

Para a classe AM, uma menor parcela foi contabilizada no cenário 1 (0,8%) em comparação às demais, sendo o maior valor para o cenário 5, com 1,9% de cobertura. O potencial para a detecção de áreas úmidas por parte de dados SAR utilizando o retroespalhamento em σ^0 é evidenciado por Chatziantoniou et al. (2017), entretanto, ao adotar o γ^0 no presente estudo, a quantificação dessas áreas apresentou baixos valores de cobertura, o que diverge de estudos que vem sendo apresentado no meio científico onde pesquisas recentes destacam a possibilidade de obter resultados mais fidedignos para regiões úmidas utilizando o retroespalhamento em γ^0 (Arias et al., 2022).

É importante ressaltar ainda nesta classe (AM), que na etapa de análise de separabilidade pelo retroespalhamento, 50% das ocorrências desta classe indicaram incapacidade de distinção, isso

sugere que as informações de decomposição polarimétrica e coerência interferométrica por si só, não foram suficientes para estimar com maior eficácia áreas úmidas. Todavia os melhores resultados para a discriminação destas áreas estão relacionados a utilização da banda 11 (SWIR), já que essa é conhecida por fornecer informações independentes relacionadas à água da cultura e/ou teor de proteína (García-Haro et al., 2020).

Vários estudos recentes utilizando dados do Sentinel-2 têm demonstrado a importância da utilização desta banda na identificação de tipos de culturas agrícolas irrigadas e sujeitas a inundação (Campos-Taberner et al., 2019; Kobayashi et al., 2020).

Para a classificação das áreas urbanas (AU) as diferenças computadas mostram-se insignificantes, possivelmente devido ao percentual de área pequeno em relação ao total da área classificada. Os valores mínimos e máximos são vistos nos cenários 1 (0,41%) e cenários 3 e 6 (0,44%), respectivamente.

Contudo, na utilização de produtos S-1 para complementar o uso de imagens S-2, a separabilidade (delimitação dos limites) do contexto urbano tende a ser mais evidenciado, bem como as linhas de bordas de floresta arbórea, comportamento evidenciado também em estudos como o de Lopes et al. (2020), isto devido a capacidade do SAR de interpretar diferentes coeficientes dos mecanismos de dispersão provindos do S-1, como o *double bounce* (Cloude e Pottier, 1996; 1997) como mecanismo predominante neste tipo de alvo e das informações extraídas da coerência interferométrica (Overbeck et al., 2021).

A menor variação do coeficiente de correlação complexa encontrado, calculado pelo par interferométrico indicaram a estabilidade da classe AU analisada, pelo alto grau de correlação encontrado entre as duas imagens. Jacob et al. (2020) utilizando entre outros classificadores o algoritmo de classificação RF encontraram valores elevados de acurácia global e uma melhor delimitação da área urbana em sítios de análise na Polônia, Itália e Espanha, principalmente quando combinados aos dados de intensidade.

Ao analisarmos a classe de AT, evidencia-se a generalização em destaque para o cenário 1, que apresenta o valor de 12,1% enquanto as demais classificações apresentaram 1,6%, 1,8%, 2,4%, 1,7% e 2,6%, respectivamente. Limitações entre classes com cobertura vegetal são recorrentes em

trabalhos do gênero em caso de imagens SAR, como discriminar classes de agricultura e vegetação secundária a partir de imagens Sentinel-1 (Nicolau et al., 2021) decorrente do baixo contraste radiométrico neste comprimento de onda.

Para áreas de agricultura, a utilização do Sentinel-1 em específico a partir da abordagem do retroespalhamento com o terreno achatado (γ^0), o estudo de Arias et al. (2022) revelou a influência positiva na estimativa de áreas agrícolas pela transformação dos valores de sigma zero em γ^0 diminuindo consideravelmente a influência do ângulo de incidência local por meio do achatamento do terreno e por consequência atenuando a influência deste nas polarizações VH e principalmente na VV, com isto aumentando a discriminação de cultivos de trigo.

Os próximos passos desta pesquisa serão utilizar a sinergia dos dados ópticos e SAR com técnicas mais robustas de DL baseadas em informação semântica e recorrência como U-Net e LSTM. Estas redes profundas têm apresentado bons resultados em diferentes biomas do Brasil alcançando acurácia global maiores que 90%, como reportado nos estudos com dados ópticos de Marreto et al. (2020) e Matosak et al. (2022).

Conclusões

Os resultados alcançados a partir da utilização conjunta de dados Sentinel 1 e 2, enfatizam a possibilidade de melhorias para a classificação de uso e cobertura da terra, considerando o ganho na precisão de classificação. Quando integrados os produtos gerados por ambos os sensores, óptico e SAR, o algoritmo de classificação RF, baseado em metodologia de ML, demonstrou boa capacidade para distinção das sete classes com acurácia entre 0,59 a 0,89.

O valor mais baixo de F1 score apresentado pelo cenário 1, evidenciou maiores conflitos para as classes de agricultura (AT) e área úmida (AM), que persistiram nas demais combinações, fato que pode ter sua causa devido a ocorrência de áreas classificadas como úmidas em áreas de plantios de arroz irrigado.

A estratégia de determinação das amostras a partir de grupos estatísticos demonstrou adequação para o mapeamento, mantendo um nível adequado de generalização por cada classe.

A coerência interferométrica, que vem sendo utilizada de forma frequente em estudos

desta natureza, demonstrou ser adequada para a classificação do uso da terra, principalmente em se tratando do reconhecimento de áreas urbanas e na identificação de bordas ou transições de estágios nas florestas.

A utilização de dados de retroespalhamento, coerência interferométrica e decomposição dual de Cloude e Pottier, a qual utiliza a fase polarimétrica de dados SAR do S1, em combinação com as bandas do óptico do S2 na região do visível e do infravermelho próximo apresentou os melhores resultados, comprovados pelos altos valores das métricas de validação obtidas.

Contudo, estudos futuros que explorem a utilização do *backscattering* em γ^0 e em β^0 a partir da utilização de padrões estatísticos devem ser realizados, tendo em vista o baixo reconhecimento de áreas úmidas e confusão com áreas agrícolas, principalmente de culturas irrigadas. Devem ser consideradas séries temporais com o estudo do comportamento do sinal de retroespalhamento em ângulo de incidência específico, tipo de relevo e sazonalidade, acrescido de avaliações por abordagem recorrente e técnicas de aprendizagem residual.

Os resultados obtidos nesta pesquisa fazem parte e se mostraram promissores no estudo do estabelecimento da escolha do melhor método de classificação e das variáveis mais adequadas para comporem o algoritmo de classificação supervisionada utilizando técnicas de inteligência artificial (IA) via algoritmos de classificação de *machine* e *deep learning* a serem aplicadas em uma análise multitemporal em cubo de dados, já em fase de teste pelo Instituto Nacional de Pesquisas Espaciais (INPE) para a classificação do bioma pampa de forma contínua em substituição ao método de classificação visual realizada pelo fotointérprete.

Agradecimentos

Ao CNPq pela concessão da bolsa de pesquisa ao primeiro autor, assim como o Projeto 409336/2021-1 pelos recursos para compra de computadores. Ao Censipam pelo apoio institucional na utilização do Plug-in Planet Explore em acordo com a Rede Mais/MJSP.

Referências

- Adugna, T., Xu, W., & Fan, J. (2022). Comparison of random forest and support vector machine classifiers for regional land cover mapping using coarse resolution FY-3C images. *Remote Sensing*, 14(3), 574. doi:10.3390/rs14030574.
- Agência Espacial Europeia WorldCover. Disponível em: <https://esa-worldcover.org/en>. Acesso 21 de jan. de 2023.
- Almeida, C. A. D., Coutinho, A. C., Esquerdo, J. C. D. M., Adami, M., Venturieri, A., Diniz, C. G., ... & Gomes, A. R. (2016). High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amazonica*, 46, 291-302. doi:10.1590/1809-4392201505504.
- Andrade, R., Silva, S. H. G., Weindorf, D. C., Chakraborty, S., Faria, W. M., Guilherme, L. R. G., & Curi, N. (2021). Micronutrients prediction via pXRF spectrometry in Brazil: Influence of weathering degree. *Geoderma Regional*, 27, e00431. doi:10.1016/j.geodrs.2021.e00431.
- Arias, M., Campo-Bescós, M. Á., & Álvarez-Mozos, J. (2022). On the influence of acquisition geometry in backscatter time series over wheat. *International Journal of Applied Earth Observation and Geoinformation*, 106, 102671. doi:10.1016/j.jag.2021.102671.
- Arveti, N., Etikala, B., & Dash, P. (2016). Land use/land cover analysis based on various comprehensive geospatial data sets: a case study from Tirupati area, south India. *Advances in Remote Sensing*, 5(02), 73. doi:10.4236/ars.2016.52006.
- Baeza, S., Vélez-Martin, E., De Abelleira, D., Bancho, S., Gallego, F., Schirmbeck, J., ... & Hasenack, H. (2022). Two decades of land cover mapping in the Río de la Plata grassland region: The MapBiomass Pampa initiative. *Remote Sensing Applications: Society and Environment*, 28, 100834. doi: 10.1016/j.rsase.2022.100834.
- Barbosa, F. L. R., Guimarães, R. F., Carvalho Júnior, O. A. D., & Gomes, R. A. T. (2021). Land Use/Land Cover (LULC) classification based on SAR/Sentinel 1 image in Distrito Federal, Brazil. *Sociedade & Natureza*, 33. doi:10.14393/SN-v33-2021-55954.
- Bazzi, H., Baghdadi, N., Ienco, D., El Hajj, M., Zribi, M., Belhouichette, H., ... & Demarez, V. (2019). Mapping irrigated areas using Sentinel-1 time series in Catalonia, Spain. *Remote Sensing*, 11(15), 1836. doi:10.3390/rs11151836.
- Biaou, S., Gouwakinnou, G. N., Biaou, H. S. S., Tovihessi, M. S., Awessou, B. K., Ahononga, F. C., & Houéto, F. O. (2021). Identifying the land use and land cover change drivers: methods and case studies of two forest reserves in Northern Benin. *Environment, Development and Sustainability*, 1-21. doi: 10.1007/s10668-021-01849-4.
- Billah, M., Islam, A. S., Mamoon, W. B., & Rahman, M. R. (2023). Random forest classifications for landuse mapping to assess rapid flood damage using Sentinel-1 and Sentinel-2 data. *Remote Sensing Applications: Society and Environment*, 30, 100947. doi:10.1016/j.rsase.2023.100947.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brentano, B., Follmann, F. M., & Foletto, E. (2015). Contextualização das unidades de conservação no estado do Rio Grande do Sul, Brasil. *Ciência e Natura*, 37(3), 536-554. doi: 105902/2179460X17278.
- Bruggisser, M., Dorigo, W., Dostálová, A., Hollaus, M., Navacchi, C., Schlaffer, S., & Pfeifer, N. (2021). Potential of Sentinel-1 C-band time series to derive structural parameters of temperate deciduous forests. *Remote Sensing*, 13(4), 798. doi:10.3390/rs13040798.
- Caballero, C. B., Biggs, T. W., Vergopolan, N., West, T. A., & Ruhoff, A. (2023). Transformation of Brazil's biomes: The dynamics and fate of agriculture and pasture expansion into native vegetation. *Science of The Total Environment*, 896, 166323. doi:10.1016/j.scitotenv.2021.152134.
- Campos-Taberner, M., García-Haro, F. J., Martínez, B., Sánchez-Ruiz, S., & Gilabert, M. A. (2019). A copernicus sentinel-1 and sentinel-2 classification framework for the 2020+ European common agricultural policy: A case study in València (Spain). *Agronomy*, 9(9), 556. doi:10.3390/agronomy9090556.
- Campos-Taberner, M., García-Haro, F. J., Martínez, B., Izquierdo-Verdiguier, E., Atzberger, C., Camps-Valls, G., & Gilabert, M. A. (2020). Understanding deep learning in land use classification based on Sentinel-2 time series. *Scientific reports*, 10(1), 17188. doi:10.1038/s41598-020-74215-5.
- Cao, R., Tu, W., Yang, C., Li, Q., Liu, J., Zhu, J., ... & Qiu, G. (2020). Deep learning-based remote and social sensing data fusion for urban region function recognition. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163, 82-97. doi:10.1016/j.isprsjprs.2020.02.014.

- Carreiras, J. M., Jones, J., Lucas, R. M., & Shimabukuro, Y. E. (2017). Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and radar remote sensing data. *Remote sensing of environment*, 194, 16-32. doi:10.1016/j.rse.2017.03.016.
- Çavur, M., Duzgun, H. S., Kemeç, S., & Demirkan, D. C. (2019). Land use and land cover classification of Sentinel 2-A: St Petersburg case study. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 13-16. doi:10.5194/isprs-archives-XLII-1-W2-13-2019.
- Chatziantoniou, A., Petropoulos, G. P., & Psomiadis, E. (2017). Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. *Remote Sensing*, 9(12), 1259. doi:10.3390/rs9121259.
- Chen, Y., Guerschman, J. P., Cheng, Z., & Guo, L. (2019). Remote sensing for vegetation monitoring in carbon capture storage regions: A review. *Applied energy*, 240, 312-326. doi: 10.1016/j.apenergy.2019.02.027.
- Cloude, S. R., & Pottier, E. (1996). A review of target decomposition theorems in radar polarimetry. *IEEE transactions on geoscience and remote sensing*, 34(2), 498-518. doi:10.1109/36.485127.
- Cloude, S. R., & Pottier, E. (1997). An entropy based classification scheme for land applications of polarimetric SAR. *IEEE transactions on geoscience and remote sensing*, 35(1), 68-78. doi:10.1109/36.551935.
- Cloude, S. (2007). The dual polarization entropy/alpha decomposition: A PALSAR case study. *Science and Applications of SAR Polarimetry and Polarimetric Interferometry*, 644, 2.
- Congalton, R. G., & Green, K. (2019). Assessing the accuracy of remotely sensed data: principles and practices. CRC press. doi:10.1201/9780429052729.
- Copernicus. Land Monitoring Service. CORINE Land Cover. Disponível em: <https://land.copernicus.eu/pan-european/corine-land-cover>. Acesso em: 21 de jan. de 2023.
- Costa, J. D. S., Liesenberg, V., Schimalski, M. B., Sousa, R. V. D., Biffi, L. J., Gomes, A. R., ... & Bispo, P. D. C. (2021). Benefits of combining ALOS/PALSAR-2 and Sentinel-2A data in the classification of land cover classes in the Santa Catarina southern Plateau. *Remote Sensing*, 13(2), 229. doi:10.3390/rs13020229.
- Dascălu, A., Catalão, J., & Navarro, A. (2023). Detecting Deforestation Using Logistic Analysis and Sentinel-1 Multitemporal Backscatter Data. *Remote Sensing*, 15(2), 290. doi:10.3390/rs15020290.
- Diniz, J., & Gama, F. (2019). Utilização da coerência interferométrica SAR para mapeamento do uso e cobertura da terra na região da Amazônia. *Simpósio Brasileiro de Sensoriamento Remoto*.
- Dobrinčić, D., Medak, D., & Gašparović, M. (2020). Integration of multitemporal Sentinel-1 and Sentinel-2 imagery for land-cover classification using machine learning methods. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 91-98. doi:10.5194/isprs-archives-XLIII-B1-2020-91-2020.
- Dostálová, A., Milenkovic, M., Hollaus, M., & Wagner, W. (2016, May). Influence of forest structure on the Sentinel-1 backscatter variation-analysis with full-waveform lidar data. In *Living Planet Symposium* (Vol. 740, p. 202).
- Erinjeri, J. J., Singh, M., & Kent, R. (2018). Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. *Remote Sensing of Environment*, 216, 345-354. doi:10.1016/j.rse.2018.07.006.
- Ferreira, G. H. S. (2018). Identificação de áreas inundáveis na porção sul de Roraima com auxílio de imagens de Radar.
- Fioravante, P., Luti, T., Cavalli, A., Giuliani, C., Dichicco, P., Marchetti, M., ... & Munafò, M. (2021). Multispectral sentinel-2 and sar sentinel-1 integration for automatic land cover classification. *Land*, 10(6), 611. doi:10.3390/land10060611.
- Filipponi, F. (2019). Sentinel-1 GRD preprocessing workflow. In *International Electronic Conference on Remote Sensing* (p. 11). MDPI. doi:10.3390/ECRS-3-06201.
- Fiorillo, E., Di Giuseppe, E., Fontanelli, G., & Maselli, F. (2020). Lowland rice mapping in Sédhiou Region (Senegal) using sentinel 1 and sentinel 2 data and random forest. *Remote Sensing*, 12(20), 3403. doi:10.3390/rs12203403.
- Schmitt, A.; Brisco, B. Wetland monitoring using the curvelet-based change detection method on polarimetric SAR imagery. *Water*, v. 5, n. 3, p. 1036-1051, 2013. doi:10.3390/w5031036.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote sensing of environment*, 80(1), 185-201. doi:10.1016/S0034-4257(01)00295-4.

- Freeman, A., & Durden, S. L. (1998). A three-component scattering model for polarimetric SAR data. *IEEE transactions on geoscience and remote sensing*, 36(3), 963-973. doi:10.1109/36.673687.
- Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3), 257-266. doi:10.1016/S0034-4257(96)00067-3.
- García-Haro, F. J., Campos-Taberner, M., Moreno, Á., Tagesson, H. T., Camacho, F., Martínez, B., ... & Gilabert, M. A. (2020). A global canopy water content product from AVHRR/Metop. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 77-93. doi:10.1016/j.isprsjprs.2020.02.007.
- Ghorbanian, A., Mohammadzadeh, A., & Jamali, S. (2022). Linear and non-linear vegetation trend analysis throughout Iran using two decades of MODIS NDVI imagery. *Remote Sensing*, 14(15), 3683. doi:10.3390/rs14153683.
- Ghimire, B., Rogan, J., Galiano, V. R., Panday, P., & Neeti, N. (2012). An evaluation of bagging, boosting, and random forests for land-cover classification in Cape Cod, Massachusetts, USA. *GIScience & Remote Sensing*, 49(5), 623-643. doi:10.2747/1548-1603.49.5.623.
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300. doi:10.1016/j.patrec.2005.08.011.
- Goergen, L. C. D. G., Narvaes, I. S., & Adami, M. (2021). Estimation of wood volume of *Eucalyptus dunnii* and *urograndis* of different ages using TM/Landsat 5 i. *Ciência Florestal*, 31, 683-704. doi:10.5902/1980509834751.
- Guerini Filho, M., Kuplich, T. M., & Quadros, F. L. F. D. (2020). Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. *International Journal of Remote Sensing*, 41(8), 2861–2876. https://doi.org/10.1080/01431161.2019.1697004.
- Guimarães, U. S., Galo, M. D. L. B. T., Narvaes, I. S., & da Silva, A. D. Q. (2020). Cosmo-SkyMed and TerraSAR-X datasets for geomorphological mapping in the eastern of Marajó Island, Amazon coast. *Geomorphology*, 350, 106934. doi:10.1016/j.geomorph.2019.106934.
- Hansen, J. N., Mitchard, E. T., & King, S. (2020). Assessing forest/non-forest separability using Sentinel-1 c-band synthetic aperture radar. *Remote Sensing*, 12(11), 1899. doi:10.3390/rs12111899.
- Hardy, A., Ettrich, G., Cross, D. E., Bunting, P., Liywalii, F., Sakala, J., ... & Thomas, C. J. (2019). Automatic detection of open and vegetated water bodies using Sentinel 1 to map African malaria vector mosquito breeding habitats. *Remote Sensing*, 11(5), 593. doi:10.3390/rs11050593.
- Hawryło, P., Bednarz, B., Wężyk, P., & Szostak, M. (2018). Estimating defoliation of Scots pine stands using machine learning methods and vegetation indices of Sentinel-2. *European Journal of Remote Sensing*, 51(1), 194-204. doi:10.1080/22797254.2017.1417745.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309. doi:10.1016/0034-4257(88)90106-X.
- Ibrahim, S. A. (2022). Improving Land Use/Cover Classification Accuracy from Random Forest Feature Importance Selection Based on Synergistic Use of Sentinel Data and Digital Elevation Model in Agriculturally Dominated Landscape. *Agriculture*, 13(1), 98. doi:10.3390/agriculture13010098.
- INPE. Instituto Nacional de Pesquisas Espaciais (2023). PRODES — Coordenação-Geral de Observação da Terra. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes4>. Acesso em: 21 de jan. de 2023.
- Jacob, A. W., Vicente-Guijalba, F., Lopez-Martinez, C., Lopez-Sanchez, J. M., Litzinger, M., Kristen, H., ... & Engdahl, M. E. (2020). Sentinel-1 InSAR coherence for land cover mapping: A comparison of multiple feature-based classifiers. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 535-552. doi:10.1109/JSTARS.2019.2958847.
- Jensen, J. R., & Epiphany, J. C. N. (2009). *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres* (p. 598). São José dos Campos: Parêntese Editora.
- Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., ... & Waske, B. (2016). A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 8(1), 70. doi:10.3390/rs8010070.
- Khalil, R. Z. (2018). InSAR coherence-based land cover classification of Okara, Pakistan. *The Egyptian Journal of Remote Sensing and Space Science*, 21, S23-S28. doi:10.1016/j.ejrs.2017.08.005.
- Kobayashi, N., Tani, H., Wang, X., & Sonobe, R. (2020). Crop classification using spectral indices derived from Sentinel-2A imagery. *Journal of Information and Telecommunication*, 4(1), 67-90. doi:10.1080/24751839.2019.1694765.

- Kuplich, T. M., Soler, L., Narvaes, I. S., Peixoto, D., Trindade, P., Silveira, G., & Almeida, C. (2023). Brazilian Pampa as part of the INPE's official program for mapping native vegetation removal. Abstracts of the ICA, 6, 130. doi:10.5194/ica-abs-6-130-2023.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 33(1), 159-174. doi:10.2307/2529310.
- Lee, J. S. (1980). Digital image enhancement and noise filtering by use of local statistics. *IEEE transactions on pattern analysis and machine intelligence*, (2), 165-168. doi:10.1109/TPAMI.1980.4766994.
- Lee, J. S. (1981). Speckle analysis and smoothing of synthetic aperture radar images. *Computer graphics and image processing*, 17(1), 24-32. doi:10.1016/S0146-664X(81)80005-6.
- Lobert, F., Holtgrave, A. K., Schwieder, M., Pause, M., Vogt, J., Gocht, A., & Erasmi, S. (2021). Mowing event detection in permanent grasslands: Systematic evaluation of input features from Sentinel-1, Sentinel-2, and Landsat 8 time series. *Remote Sensing of Environment*, 267, 112751. doi:10.1016/j.rse.2021.112751.
- Lopes, M., Frison, P. L., Durant, S. M., Schulte to Bühne, H., Ipavec, A., Lapeyre, V., & Pettorelli, N. (2020). Combining optical and radar satellite image time series to map natural vegetation: savannas as an example. *Remote Sensing in Ecology and Conservation*, 6(3), 316-326. doi:10.1002/rse2.139.
- Mamun, A. A., Mahmood, A., Rahman, M. 2013. Identification and monitoring the change of land use pattern using remote sensing and GIS: A case study of Dhaka City. *IOSR Journal of Mechanical and Civil Engineering*, 6(2), pp.20-28.
- Mapbiomas Brasil. Disponível em: <https://mapbiomas.org/en>. Acessado em: 21 de jan. de 2023.
- Maretto, R. V., Fonseca, L. M., Jacobs, N., Körting, T. S., Bendini, H. N., & Parente, L. L. (2020). Spatio-temporal deep learning approach to map deforestation in amazon rainforest. *IEEE Geoscience and Remote Sensing Letters*, 18(5), 771-775. doi:10.1109/LGRS.2020.2986407.
- Matosak, B. M., Fonseca, L. M. G., Taquary, E. C., Maretto, R. V., Bendini, H. D. N., & Adami, M. (2022). Mapping deforestation in cerrado based on hybrid deep learning architecture and medium spatial resolution satellite time series. *Remote sensing*, 14(1), 209. doi:10.3390/rs14010209.
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. doi:10.1080/01431161.2018.1433343.
- McNairn, H., Robertson, L. D., Tsan, D., Jiao, X., & Davidson, A. (2021, July). Multi-frequency SAR to monitor agriculture in the Americas. In 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS (pp. 5914-5916). IEEE. doi:10.1109/IGARSS47720.2021.9555034.
- Miguel, B. H., & Sano, E. E. (2019). Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica. *Revista Brasileira de Geografia Física*, 12(2), 427-442. doi:10.26848/rbgf.v12.2.p427-442.
- Ministério do Meio Ambiente – MMA. 2014. MMA Pampa. Disponível em: <https://www.gov.br/mma/pt-br/noticias/a-biodiversidade-pouco-conhecida-do-pampa>. Acesso em 16 de jan. de 2023.
- Mohammadimanesh, F., Salehi, B., Mahdianpari, M., Brisco, B., & Motagh, M. (2018). Multi-temporal, multi-frequency, and multi-polarization coherence and SAR backscatter analysis of wetlands. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142, 78-93. doi:10.1016/j.isprsjprs.2018.05.009.
- Narvaes, I. S., Santos, J. R. D., & Silva, A. D. Q. D. (2010). Análise dos parâmetros estruturais de tipologias florestais utilizando dados SAR em banda L. *Boletim de Ciências Geodésicas*, 16, 475-489. doi:10.1590/S1982-21702010000300007.
- Nery, T., Sadler, R., Solis-Aulestia, M., White, B., Polyakov, M., & Chalak, M. (2016, July). Comparing supervised algorithms in Land Use and Land Cover classification of a Landsat time-series. In 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS) (pp. 5165-5168). IEEE. doi:10.1109/IGARSS.2016.7730346.
- Nicolau, A. P., Flores-Anderson, A., Griffin, R., Herndon, K., & Meyer, F. J. (2021). Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest. *International Journal of Applied Earth Observation and Geoinformation*, 94, 102214. doi:10.1016/j.jag.2020.102214.
- Niculescu Sr, S., Billey, A., & Talab-Ou-Ali Jr, H. (2018, October). Random forest classification using Sentinel-1 and Sentinel-2 series for vegetation monitoring in the Pays de Brest (France). In *Remote Sensing for Agriculture, Ecosystems, and Hydrology XX* (Vol. 10783, p. 1078305). SPIE. doi:10.1117/12.2325546.

- Nitze, I., Schulthess, U., & Asche, H. (2012). Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th GEOBIA*, Rio de Janeiro, Brazil, 79, 3540.
- Novo, E. M. L. D. M., & Costa, M. P. (2005). Fundamentos e aplicações de radar no estudo de áreas alagáveis. In: SOUZA, Ronald Buss (Ed.). **Oceanografia por satélites**. São José dos Campos: Oficina de Textos, 2005. v. Cap. 16, p. 236-258. ISBN 85-86238-48-1. (INPE-13109-PRE/8369). Disponível em: <<http://urlib.net/ibi/6qtX3pFwXQZ3r59YD6/HQj9>>.
- Olesk, A., Praks, J., Antropov, O., Zalite, K., Arumäe, T., & Voormansik, K. (2016). Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data. *Remote Sensing*, 8(9), 700. doi:10.3390/rs8090700.
- Overbeck, G. E., Vélez-Martin, E., Scarano, F. R., Lewinsohn, T. M., Fonseca, C. R., Meyer, S. T., ... & Pillar, V. D. (2015). Conservation in Brazil needs to include non-forest ecosystems. *Diversity and distributions*, 21(12), 1455-1460. doi:10.1111/ddi.12380.
- Paradella, W. R., Mura, J. C., & Gama, F. F. (2021). Monitoramento DInSAR para mineração e geotecnia. Oficina de Textos.
- Pavanelli, J. A. P., Santos, J. R. D., Galvão, L. S., Xaud, M., & Xaud, H. A. M. (2018). PALSAR-2/ALOS-2 and OLI/LANDSAT-8 data integration for land use and land cover mapping in northern Brazilian Amazon. *Boletim de Ciências Geodésicas*, 24, 250-269. doi:10.1590/S1982-21702018000200017.
- Planet Labs. (2022). "Planet Imagery Product Specifications," São Francisco. Acesso em 02 mar. 2022. Disponível em: <https://assets.planet.com/docs>.
- Plank, S., Jüssi, M., Martinis, S., & Twele, A. (2017). Mapping of flooded vegetation by means of polarimetric Sentinel-1 and ALOS-2/PALSAR-2 imagery. *International Journal of Remote Sensing*, 38(13), 3831-3850. doi:10.1080/01431161.2017.1306143.
- Pompêo, M., Sòria-peprinyà, X., Garcia, M. S., Delegido, J., Urrego, E. P.; Pereira-Sandoval, M. A., Vicente, E. (2019). Sentinel 2 (A e B): protocolo de instalação e uso para trabalhar imagens na avaliação da qualidade da água de reservatórios. São Paulo: Instituto de Biociências, 38 p. doi:10.11606/9788585658786.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2012). Sensoriamento remoto da vegetação. atual e ampl. São Paulo: Oficina de Textos.
- Pôssa, E. M., Gama, F. F., Santos, J. R., Mura, J. C., & Bispo, P. C. (2018). Análise de uso da terra e cobertura florestal na Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X. *Revista Brasileira de Geografia Física*, 11(6), 2094-2108. doi:10.26848/rbgf.v11.6.p2094-2108.
- Qasim, M., Csaplovics, E., & Villegas, M. H. S. (2023). Forest biomass assessment combining field inventorying and remote sensing data. *Open Geosciences*, 15(1), 20220553. doi: 10.1515/geo-2022-0553.
- Quegan, S., Le Toan, T., Yu, J. J., Ribbes, F., & Floury, N. (2000). Multitemporal ERS SAR analysis applied to forest mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 38(2), 741-753. doi:10.1109/36.842003.
- Quegan, S., & Yu, J. J. (2001). Filtering of multichannel SAR images. *IEEE Transactions on geoscience and remote sensing*, 39(11), 2373-2379. doi:10.1109/36.964973.
- Raczko, E., & Zagajewski, B. (2017). Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. *European Journal of Remote Sensing*, 50(1), 144-154. doi:10.1080/22797254.2017.1299557.
- Richards, J. A., Woodgate, P. W., & Skidmore, A. K. (1987). An explanation of enhanced radar backscattering from flooded forests. *International Journal of Remote Sensing*, 8(7), 1093-1100. doi:10.1080/01431168708954756.
- Rivas, M., Vidal, R., Neitzke, R. S., Priori, D., Almeida, N., Antunes, I. F., ... & Barbieri, R. L. (2023). Diversity of vegetable landraces in the Pampa biome of Brazil and Uruguay: utilization and conservation strategies. *Frontiers in Plant Science*, 14, 1232589. doi: 10.3389/fpls.2023.1232589.
- Roberti, D. R., Mergen, A., Gotuzzo, R. A., Veeck, G. P., Bremm, T., Marin, L., ... & Jacques, R. J. S. (2024). Sustainability in Natural Grassland in the Brazilian Pampa Biome: Livestock Production with CO2 Absorption. *Sustainability*, 16(9), 3672.
- Rocha, N. S., Veettil, B. K. Ward, R. D., Costi, J., & Rolim, S. B. A. (2023). Remote sensing of grasslands in the South American Pampas

- (scientometrics analysis). *Land Degradation & Development*, 34(10), 2723-2734. doi:10.1002/ldr.4658.
- Roesch, L. F. W., Vieira, F. C. B., Pereira, V. A., Schünemann, A. L., Teixeira, I. F., Senna, A. J. T., & Stefenon, V. M. (2009). The Brazilian Pampa: a fragile biome. *Diversity*, 1(2), 182-198. doi:10.3390/d1020182.
- Rosa, M. R. (2018). Classificação do padrão de ocupação urbana de São Paulo utilizando aprendizagem de máquina e Sentinel 2. *Revista do Departamento de Geografia*, 15-21. doi:0000-0001-5367-8059.
- Rosembach, R., França, A. M. S., & Florenzano, T. G. (2005). Análise comparativa dos dados NDVI obtidos de imagens CCD/CBERS-2 e TM/LANDSAT-5 em área urbana. *Simpósio Brasileiro de Sensoriamento Remoto*, 12(2005), 1075-1082.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ.*, 351(1), 309.
- Shi, J.; Dozier, J.; Rott, H.. Snow mapping in alpine regions with synthetic aperture radar. *IEEE Transactions on Geoscience and Remote Sensing*, v. 32, n. 1, p. 152-158, 1994. doi:10.1109/36.285197.
- Shuai, G., Zhang, J., Basso, B., Pan, Y., Zhu, X., Zhu, S., & Liu, H. (2019). Multi-temporal RADARSAT-2 polarimetric SAR for maize mapping supported by segmentations from high-resolution optical image. *International Journal of Applied Earth Observation and Geoinformation*, 74, 1-15. doi:10.1016/j.jag.2018.08.021.
- Small, D. (2011). Flattening gamma: Radiometric terrain correction for SAR imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 49(8), 3081-3093. doi:10.1109/TGRS.2011.2120616.
- Tavares, P. A., Beltrão, N. E. S., Guimarães, U. S., & Teodoro, A. C. (2019). Integration of sentinel-1 and sentinel-2 for classification and LULC mapping in the urban area of Belém, eastern Brazilian Amazon. *Sensors*, 19(5), 1140. doi:10.3390/s19051140.
- Thanh Noi, P., & Kappas, M. (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 18(1), 18. doi:10.3390/s18010018.
- Torbick, N., Chowdhury, D., Salas, W., & Qi, J. (2017). Monitoring rice agriculture across Myanmar using time series Sentinel-1 assisted by Landsat-8 and PALSAR-2. *Remote Sensing*, 9(2), 119. doi:10.3390/rs9020119.
- Trindade, P. M. P., Peixoto, D. W. B., Kuplich, T. M., & de Almeida, C. A. (2021). LAND COVER MAPPING IN THE BRAZILIAN PAMPA WITH LANDSAT OLI AND TIRS BANDS: Mapeamento da cobertura de terra no Pampa Brasileiro com LANDSAT OLI e BANDA TIRS. *Geosciences= Geociências*, 40(4), 1115-1124. doi:10.5016/geociencias.v40i04.15930.
- Trindade, P. M. P., Peixoto, D. W. B., Silveira, G. V., Kuplich, T. . M., & Narvaes, I. S. (2023). Mapeamento de cobertura e uso da terra no bioma Pampa utilizando diferentes sensores orbitais e classificador Random Forest. *Revista Geografias*, 19(2), 60–82. https://doi.org/10.35699/2237-549X.2023.46915.
- Ulaby, F. T., & Elachi, C. (1990). *Radar Polarimetry for Geoscience Applications*, 364 p., Artech House. Inc., MA.
- Valero, M. A. M., Araújo, W. F., Melo, V. F., Augusti, M. L., & Fernandes Filho, E. I. (2022). Land-use and land-cover mapping using a combination of radar and optical sensors in Roraima–Brazil. *Engenharia Agrícola*, 42, e20210142. doi:10.1590/1809-4430-Eng.Agric.v42n2e20210142/2022.
- Vicente, L., Souza Filho, C. R., & Perez Filho, A. (2007). O uso do infravermelho de ondas curtas (SWIR) no mapeamento de fitofisionomias em ambiente tropical por meio de classificação hiperespectral de dados do sensor ASTER. In *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto* (pp. 1915-1922).
- Werner, A., Storie, C. D., & Storie, J. (2014). Evaluating SAR-optical image fusions for urban LULC classification in Vancouver Canada. *Canadian Journal of Remote Sensing*, 40(4), 278-290. doi:10.1080/07038992.2014.976700.
- Whyte, A., Ferentinos, K. P., & Petropoulos, G. P. (2018). A new synergistic approach for monitoring wetlands using Sentinels-1 and 2 data with object-based machine learning algorithms. *Environmental Modelling & Software*, 104, 40-54. doi:10.1016/j.envsoft.2018.01.023.
- Woodhouse, I. H., 2017. *Introduction to Microwave Remote Sensing*. CRC Press/Taylor & Francis, New York. doi:10.1201/9781315272573.
- Jin, Y., Liu, X., Chen, Y., & Liang, X. (2018). Land-cover mapping using Random Forest classification and incorporating NDVI time-series and texture: A case study of central Shandong. *International*

- journal of remote sensing, 39(23), 8703-8723. doi:10.1080/01431161.2018.1490976.
- Zakeri, H., Yamazaki, F., & Liu, W. (2017). Texture analysis and land cover classification of Tehran using polarimetric synthetic aperture radar imagery. *Applied Sciences*, 7(5), 452. doi:10.3390/app7050452.
- Zeferino, L. B., de Souza, L. F. T., do Amaral, C. H., Fernandes Filho, E. I., & de Oliveira, T. S. (2020). Does environmental data increase the accuracy of land use and land cover classification?. *International Journal of Applied Earth Observation and Geoinformation*, 91, 102128. doi:10.1016/j.jag.2020.102128.
- Zhang, B., Wdowinski, S., Gann, D., Hong, S. H., & Sah, J. (2022). Spatiotemporal variations of wetland backscatter: The role of water depth and vegetation characteristics in Sentinel-1 dual-polarization SAR observations. *Remote Sensing of Environment*, 270, 112864. doi:10.1016/j.rse.2021.112864.
- Zhang, W., Brandt, M., Wang, Q., Prishchepov, A. V., Tucker, C. J., Li, Y., ... & Fensholt, R. (2019). From woody cover to woody canopies: How Sentinel-1 and Sentinel-2 data advance the mapping of woody plants in savannas. *Remote Sensing of Environment*, 234, 111465. doi:10.1016/j.rse.2019.111465.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote*.