

UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL

DETECÇÃO DOS IMPACTOS DA EXPLORAÇÃO FLORESTAL EM ÁREA
MANEJADA NA AMAZÔNIA OCIDENTAL USANDO SENSOR SAR E ÓPTICO

MOISÉS PARREIRAS PEREIRA

DISSERTAÇÃO DE MESTRADO

RIO BRANCO-AC, BRASIL
JANEIRO DE 2024

UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA FLORESTAL

DETECÇÃO DOS IMPACTOS DA EXPLORAÇÃO FLORESTAL EM ÁREA
MANEJADA NA AMAZÔNIA OCIDENTAL USANDO SENSOR SAR E ÓPTICO

MOISÉS PARREIRAS PEREIRA

Dissertação apresentada ao Programa de Pós-Graduação em Ciência Florestal da Universidade Federal do Acre, como requisito parcial à obtenção do título de Mestre.

Orientadora: Prof. Dra. Symone Maria de Melo Figueiredo

RIO BRANCO-AC, BRASIL

JANEIRO DE 2024

Ficha catalográfica elaborada pela Biblioteca Central da UFAC

P436d Pereira, Moisés Parreiras, 1996 -

Detecção dos impactos da exploração florestal em área manejada na Amazônia Ocidental usando sensor SAR e óptico / Moisés Parreiras Pereira; orientadora: Dr^a. Symone Maria de Melo Figueiredo – 2024.

56 f.: il.; 30 cm.

Dissertação (Mestrado) – Universidade Federal do Acre, Programa de Pós-Graduação em Ciência Florestal, Rio Branco, 2024.

Inclui referências bibliográficas.

1. Sensoriamento remoto. 2. Segmentação. 3. Manejo florestal. I. Figueiredo, Symone Maria de Melo (orientador). II. Título.

CDD: 634



UNIVERSIDADE FEDERAL DO ACRE
PROGRAMA DE PÓS-GRADUAÇÃO STRICTO SENSU EM CIÊNCIA FLORESTAL-PPG/CIFLOR

ATA DE DEFESA DE MESTRADO

ATA DE SESSÃO PÚBLICA DE DEFESA DE DISSERTAÇÃO DE MOISÉS PARREIRA PEREIRA, DISCENTE DO PROGRAMA DE PÓS - GRADUAÇÃO, STRICTO SENSU, EM CIÊNCIA FLORESTAL, DA UNIVERSIDADE FEDERAL DO ACRE.

Às oito horas e trinta minutos do dia vinte e quatro de janeiro de 2024, realizou-se, de forma online, por meio da plataforma Google Meet, a Sessão Pública de Defesa de Dissertação, intitulada: **"Detecção dos impactos da Exploração Florestal em área manejada na Amazônia Ocidental usando sensor SAR e óptico"**, de autoria do mestrando **Moisés Parreira Pereira**, discente do Programa de Pós - graduação em Ciência Florestal, da Universidade Federal do Acre - UFAC, em nível de Mestrado. Na ocasião, a Banca Examinadora esteve constituída pelos (as) membros (as): **Profª. Drª. Symone Maria de Melo Figueiredo (Presidente - orientadora - CCBN - Ufac); Drª. Quétila Souza Barros (Membra Externa - Bolsista pós - doutorado - INPA); Profª. Drª. Anelena Lima de Carvalho (Membra Externa- CMULTI- Ufac - Campus Floresta)**. Logo após a exposição oral, houve arguição pelos Examinadores e, ao final da arguição, reaberta a sessão pública, o discente foi considerado **aprovado** pela Banca Examinadora. E ao término, foi lavrada a presente Ata, que será assinada pelos avaliadores.

Rio Branco, 24 de janeiro de 2024.

Assinado Eletronicamente

PROFª. DRª. SYMONE MARIA DE MELO FIGUEIREDO

Presidente - orientadora - CCBN - Ufac

Assinado Eletronicamente

PROFª. DRª. QUÉTILA SOUZA BARROS

Membra Externa - Bolsista pós - doutorado - INPA

Assinado Eletronicamente

PROF^a. DR^a. ANELENA LIMA DE CARVALHO

Membra Externa- CMULTI- Ufac - Campus Floresta



Documento assinado eletronicamente por **Symone Maria de Melo Figueiredo, Professora do Magisterio Superior**, em 25/01/2024, às 08:54, conforme horário de Rio Branco - AC, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **QUÉTILA SOUZA BARROS, Usuário Externo**, em 25/01/2024, às 10:24, conforme horário de Rio Branco - AC, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Anelena Lima de Carvalho, Professora do Magisterio Superior**, em 29/01/2024, às 11:25, conforme horário de Rio Branco - AC, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade do documento pode ser conferida no site https://sei.ufac.br/sei/valida_documento ou click no link [Verificar Autenticidade](#) informando o código verificador **1164246** e o código CRC **F06B8A5E**.

Rod. BR-364 Km-04 - Bairro Distrito Industrial
CEP 69920-900 - Rio Branco-AC
- <http://www.ufac.br>

Referência: Processo nº 23107.001795/2024-66

SEI nº 1164246

REFERÊNCIA BIBLIOGRÁFICA

PEREIRA, P. M. (2024). Detecção dos impactos da exploração florestal em área manejada na Amazônia Ocidental usando sensor SAR e óptico. Dissertação de Mestrado em Ciência Florestal. Programa de Pós-graduação em Ciência Florestal, Universidade Federal do Acre, Rio Branco-AC, 67 p.

CESSÃO DE DIREITOS

AUTOR: MOISÉS PARREIRAS PEREIRA

GRAU: Mestre

Concedo à Universidade Federal do Acre-UFAC permissão para reproduzir cópias desta dissertação de mestrado e para emprestá-las somente para propósitos acadêmicos e científicos. Reservo outros direitos de publicação, de forma que nenhuma parte desta dissertação de mestrado pode ser reproduzida sem minha autorização por escrito.

Moisés Parreiras Pereira

Endereço eletrônico: moises.pereira@sou.ufac.br

“O mistério da vida me causa a mais forte
emoção, é o sentimento que suscita a beleza e
a verdade, cria a arte e a ciência”

Albert Einstein

AGRADECIMENTOS

Agradeço primeiramente a meus pais, minha base que me apoiam nos meus sonhos e objetivos, sempre me dando suporte e orientações.

Grato a meus irmãos que são meus irmãos Sael e Clara por serem minha inspiração e referência para alcançar meus objetivos.

Gratidão aos meus amigos e todas as pessoas que estiveram ao meu lado ao longo desta jornada de mestrado, pelo apoio incansável, o suporte emocional que me ofereceram foram essenciais para que eu enfrentasse os desafios e superasse os obstáculos ao longo dessa caminhada.

Sou grato a minha orientadora, Symone, pela paciência e compreensão quanto às minhas limitações e direcionamentos na pesquisa, pela atenção e ensinamentos.

Sou grato a Universidade Federal do Acre, em especial a todos professores que me formaram e técnicos que deram sempre suporte para direcionar um ambiente propício para minha formação.

Expresso novamente minha profunda gratidão à minha família, amigos, e ao Programa CIFLOR, CAPES (Amazônia Legal) e a todos que contribuíram para minha jornada acadêmica.

Seu apoio, incentivo e suporte foram fundamentais para o meu sucesso.

À CAPES pela concessão da bolsa de estudos.

SUMÁRIO

Resumo	1
Abstract.....	2
1 Introdução.....	3
2 Material e Métodos.....	5
2.1 Área de estudo	5
2.2 Plano operacional anual – POA.....	6
2.3 Infraestrutura de exploração	7
2.4 Imagens Sentinel e PlanetScope	8
2.5 <i>Google Earth Engine</i> (GEE).....	10
2.6 Pré-processamento das imagens SAR	11
2.7 Processamento e análise de imagens SAR	12
2.8 Processamento e análise de imagens ópticas	14
2.9 Validação do Mapeamento	15
3 Resultados.....	17
4 Discussão	28
5 Conclusão	31
Referências Bibliográficas.....	32
Anexos	42

DETECÇÃO DOS IMPACTOS DA EXPLORAÇÃO FLORESTAL EM ÁREA MANEJADA NA AMAZÔNIA OCIDENTAL USANDO SENSOR SAR E ÓPTICO

Moisés Parreiras Pereira^{1,3}, Symone Maria de Melo Figueiredo²

¹Programa de Pós-Graduação em Ciência Florestal, Universidade Federal do Acre (UFAC), Caixa postal 500, 69920-900, Rio Branco, AC, Brasil

²Centro de Ciências Biológicas e da Natureza, Ufac, Caixa postal 500, 69920-900, Rio Branco, AC, Brasil

³Autor para correspondência: moises.pereira@sou.ufac.br

*Conforme normas do periódico Ciência Florestal

Resumo

Este estudo buscou utilizar dados de sensores ativo e passivo para monitorar as alterações na vegetação após o manejo florestal em uma Unidade de Produção Anual (UPA) na Amazônia, explorada em 2020. As imagens do Radar de Abertura Sintética do Sentinel-1, com polarizações VV e VH, juntamente com as imagens dos satélites Planet e Sentinel-2, foram obtidas e processadas utilizando o Google Earth Engine e o QGIS 3.22. O Sentinel-1 foi utilizado como uma alternativa para identificar as mudanças na vegetação na área manejada, devido à sua menor susceptibilidade a interferências atmosféricas e cobertura de nuvens, comuns na Amazônia. No entanto, os resultados indicaram que as imagens de radar do Sentinel-1 não tiveram um desempenho satisfatório na detecção das áreas de estradas e clareiras dentro da floresta utilizando a banda-C, onde foi possível identificando apenas 1,44% da área aberta pela exploração madeireira total de 85,56 ha explorados. Em contraste, o satélite Planet como validação da exploração identificou 2,62% da área aberta equivalente a 154,38 ha, o Sentinel-2 identificou 3,11% apresentou o equivalente de área em 183,49 ha. A análise dos resultados revelou que o padrão de retroespalhamento observado na imagem de radar não foi alterado significativamente na área manejada após a exploração madeireira, dificultando a identificação das áreas de abertura de estradas e pequenas clareiras na UPA. Os resultados da imagem sentinel-2 tiveram maior precisão um valor de 81,30% de exatidão global e índice kappa de 0,72 e o Sentinel-1 teve um valor de 62,60% exatidão global e o índice Kappa de 0,44. Portanto, apesar do potencial do sensor SAR para monitorar mudanças na vegetação em áreas manejadas, este estudo destaca a necessidade de abordagens complementares para ter melhor precisão da detecção com sensor SAR e sensores ópticos.

Palavras-chave: Sensoriamento Remoto, Segmentação, Manejo Florestal.

Abstract

DETECTING THE IMPACTS OF LOGGING IN A MANAGED AREA IN THE WESTERN AMAZON USING SAR AND OPTICAL SENSORS

This study sought to use data from active and passive sensors to monitor changes in vegetation following forest management in an Annual Production Unit (APU) in the Amazon, logged in 2020. Images from the Sentinel-1 Synthetic Aperture Radar, with VV and VH polarizations, together with images from the Planet and Sentinel-2 satellites, were obtained and processed using Google Earth Engine and QGIS 3.22. Sentinel-1 was used as an alternative to identify changes in vegetation in the managed area, due to its lower susceptibility to atmospheric interference and cloud cover, which are common in the Amazon. However, the results indicated that the Sentinel-1 radar images did not perform satisfactorily in detecting the areas of roads and clearings within the forest using the C-band, where it was possible to identify only 1.44% of the area opened up by logging, with a total of 85.56 ha logged. In contrast, the Planet satellite used to validate logging identified 2.618% of the open area, equivalent to 154.38 ha, while Sentinel-2 identified 3.11%, giving an equivalent area of 183.49 ha. Analysis of the results revealed that the backscatter pattern observed in the radar image was not significantly altered in the area managed after logging, making it difficult to identify the areas where roads were opened and small clearings in the UPA. The results of the Sentinel-2 image were more accurate, with 81.3% overall accuracy and a kappa index of 0.72, while Sentinel-1 had 62.6% overall accuracy and a kappa index of 0.44. Therefore, despite the potential of the SAR sensor to monitor changes in vegetation in managed areas, this study highlights the need for complementary approaches to have better detection accuracy with the SAR sensor and optical sensors.

Key words: Remote Sensing, Segmentation, Forest Management.

1 Introdução

A floresta amazônica desempenha um papel crucial em relação ao equilíbrio e a captação de carbono da atmosfera e a preservação do meio ambiente natural (Hansen *et al.* 2013, Lu *et al.*, 2016; Boulton *et al.*, 2022), entre os serviços ecossistêmicos, destaca-se o manejo florestal, que cada vez mais tem sido utilizado pela sociedade como alternativa para garantia e conservação da floresta.

O manejo florestal é uma técnica essencial para assegurar o desenvolvimento sustentável, com ênfase na gestão cuidadosa da floresta para garantir sua preservação (Boulton *et al.*, 2022). Isso é alcançado por meio de práticas de exploração consolidadas de acordo com a legislação ambiental vigente. Dessa forma, o manejo florestal contribui significativamente para mitigar ações que possam comprometer a integridade ecológica do ecossistema florestal (Rodrigues *et al.*, 2020). As mudanças associadas ao desmatamento e a diminuição da biomassa florestal na Amazônia causam impactos a manutenção dos ciclos hidrológicos e ciclo de carbono (Häggi, 2017).

Com relação a coleta de informações para o manejo florestal, nota-se que a obtenção de dados na Amazônia é limitada em função do difícil acesso a áreas remotas e de grande extensão para monitoramento, além disto, os fatores climáticos sazonais adversos contribuem para o aumento e custo de coleta de dados em campo, dificultando mensurações *in loco* (Nanni *et al.*, 2019; d' Oliveira *et al.*, 2020).

Uma alternativa para o monitoramento da vegetação e uso do solo na Amazônia é o uso de dados de sensores remotos (Shimada *et al.*, 2014; Nanni *et al.*, 2019; Sugimoto *et al.*, 2022). A aplicação de um método que possibilite o monitoramento da abertura do dossel no manejo florestal em tempo real pode assegurar o desenvolvimento de técnicas de controle e segurança, facilitando o processamento de dados de campo tornando resultados operacionais mais dinâmicos e precisos (Kuck *et al.*, 2021).

O uso dos sistemas convencionais de monitoramento mais utilizados são os sensores passivos que dependem da radiação solar, e com isso descreve a energia eletromagnética recebida de acordo com o intervalo espectral refletido, porém, quando está nublado fica inapropriado a classificação da vegetação das imagens ópticas (Menezes *et al.*, 2017; Kuck *et al.*, 2021).

A cobertura por nuvens representa um obstáculo para o monitoramento contínuo da região amazônica por meio dos sensores ópticos (Asner, 2001) e uma opção para o monitoramento da vegetação é o uso de imagens de Radar de Abertura Sintética (SAR), que

opera na faixa das micro-ondas, com comprimento de onda e frequência que propiciam a transmissão através de nuvens e fumaça (Costa *et al.*, 2011), apresentando maior eficiência, não sofrendo e bloqueio da cobertura de nuvens e luz insuficiente.

Pesquisas vem sendo realizadas para avaliar o desempenho dos sensores passivos e sensores ativos, como, por exemplo, os estudos desenvolvidos por Negri *et al.*, (2016) que usaram sensor ativo, para classificar a cobertura do solo e a vegetação, avaliando o detalhamento do desempenho desses sensores.

A classificação de imagens SAR (PALSAR-2) de sensoriamento remoto em áreas de manejo florestal, vem sendo amplamente utilizadas para o monitoramento ambiental, apresentando restrições quanto à aquisição de imagens adequadas, devido aos fatores atmosféricos como a ocorrência de nuvens e precipitações (Sugimoto *et al.*, 2022).

As imagens de radar vem sendo uma das ferramentas mais eficazes e ganhando aplicação no geoprocessamento para detectar o desmatamento (Sugimoto *et al.*, 2022). A utilização de um método de análise das áreas alteradas por meio da avaliação dos níveis de retroespalhamento das bandas SAR para avaliar a abertura de clareiras (Deutscher *et al.*, 2013; Flores-Anderson *et al.*, 2019; Lei *et al.*, 2018; Mathieu *et al.*, 2013).

Nesse contexto, os dados SAR, como a banda C do Sentinel-1, tem alto potencial de utilização em áreas florestais por serem gratuitos, regulares e padronizados (Nicolau *et al.*, 2021). A utilização do sensor SAR na detecção do desmatamento na Amazônia tem ótima eficiência por fornecer resultados de áreas alteradas em regiões que tem interferência devido a nebulosidade persistente, barreira encontrada nas imagens ópticas e a segmentação de áreas perturbadas em áreas florestais de pequena escala (Slagter *et al.*, 2023; Ferrari *et al.*, 2023).

Para aquisição de imagens de radar, processamento e análise de um grande conjunto de dados de imagens para tomada de decisões o *Google Earth Engine* (GEE) tem serie gratuita (Mutanga & Kumar, 2019). A aplicação de sensoriamento remoto permite a obtenção dos dados de forma remota que podem ser utilizados em análises ambientais capazes de confirmar informações da superfície terrestre (Huylenbroeck *et al.*, 2020).

O processamento em nuvem e linguagem *Javascript* promove processamento dos dados, diminuindo o risco da perda dos dados, facilitando a solução de problemas de alta capacidade de dados, com uso de algoritmos complexos (Gregory *et al.*, 2015).

Com isto, o objetivo deste trabalho foi avaliar o potencial das imagens SAR e imagens ópticas na identificação da abertura de estradas florestais, pátios de estocagem decorrentes da exploração madeireira ocorrida no ano de 2020 em uma Unidade de produção anual (UPA) de 5.897,36 ha do Plano de Manejo Florestal localizado no sul da Amazônia.

2 Material e Métodos

2.1 Área de estudo

A área de estudo está localizada na Unidade de Produção Anual UPA-14, de domínio privado dentro da área de manejo florestal pertencente a empresa Agro cortex Madeiras do Acre LTDA, com coordenadas geográficas latitude de 8°32'2"S e longitude 69°8'17"W. A área total do Manejo Florestal abrange os estados do Acre e Amazonas (Figura 01).




Figura 1 - Área de Manejo Florestal Sustentável - Agro cortex LTDA, destacando a UPA-14.

A Área de Manejo Florestal (AMF) possui um total de 190.208 ha, e a área da Unidade de Produção Anual (UPA-14) tem uma dimensão de 5.897,36 ha e foi explorada no ano de 2020 durante os meses de julho a outubro. Os dados vetoriais da AMF e UPA-14 foram obtidos junto à Agro cortex Madeiras do Acre LTDA e dados de campo de Inácio (2021).

O tipo de solo mais predominante é o Argissolo Vermelho Amarelo é o tipo de solo mais comum, mas também se observa uma presença significativa de Vertissolos. Esses solos são conhecidos por sua alta fertilidade natural. A topografia da área é classificada como ondulada, com inclinações que variam de 8° a 20°. Além disso, a área apresenta uma inclinação em direção à rede de drenagem (Poa, 2017).

A área total da AMF é equivalente a 190.208 ha, no qual 186.000,00 ha correspondem a área de manejo florestal, a qual satisfaz 97,8% do total, com vegetação do tipo Floresta Ombrófila Aberta de Bambu, devido à forte presença do bambu *Guadua* ssp (Ganda & Silva, 2019)

O clima da região, segundo a classificação köppen, é do tipo Am (Clima tropical de monção) em Boca do Acre o clima e em Pauini é do tipo Af (Clima tropical úmido ou super úmido) (Alvares, 2013), caracterizado por apresentar duas estações bem definidas, com temperatura média anual de aproximadamente 24,5°C, precipitação média anual entre 1900 e 2100 mm, com o período chuvoso ocorrendo entre outubro e abril e o período seco de junho a setembro (Acre, 2010; Alvares, 2013; Amaral *et al.*, 2021).

2.2 Plano operacional anual – POA

De acordo com Plano operacional anual – POA desenvolvido pela empresa Agrocortex Madeiras do Acre Agroflorestal LTDA, o inventário florestal foi realizado com auxílio de receptor GPS de navegação Garmin 78Csx e bússolas profissional Sunto. As picadas de orientação foram abertas perpendicularmente às picadas bases que delimitam os compartimentos, formando faixas de 50 metros de largura, onde foram inventariadas as árvores de interesse econômico e comercial.

Entre os meses de dezembro de 2019 a fevereiro de 2020, foi realizado o inventário florestal 100% da UPA 14, com o levantamento das espécies de interesse comercial e potencialmente comercial, nesta etapa foram apresentadas 20 espécies, mas somente 19 foram inventariadas.

A UPA 14 possui um total de 65 Unidade de trabalho - UT's com área efetiva de exploração (AEE), em média, de 78,168 hectares. Já a volumetria proposta para as espécies selecionadas para corte na AEE é de 42.075,48 m³ de um total de 3.584 árvores com uma média de volumetria de 11,74 m³ por árvore e 8,28 m³ por hectare. O POA da UPA-14 propõe a exploração de 12 espécies de interesse comercial imediato.

2.2.1 Estradas e pátios de estocagem

O manejo florestal seguiu o planejamento desenvolvido para área por meio dos dados do Modelo digital do Terreno, onde a partir da distribuição das árvores inventariadas foi aplicado o planejamento das estradas, priorizando fatores topográficos de altimetria, a rede de drenagem, microzoneamento das Unidades de Trabalho (UT) com uma restrição de declividade ($>15\%$). No geral, as estradas foram planejadas e construídas em cima dos divisores de microbacias.

A implementação dos pátios seguiu o planejamento que causaria menor impacto na vegetação, com *Skidder* de 250 metros, com características de local plano, área fora de zonas com uma declividade ($>15\%$), a área de infraestrutura da UPA 14 foi de 92,73 hectares sendo 1,57% do total da área da UPA. O planejamento das estradas seguiu critérios de ser construídas nos caminhos mais planos, seguindo a divisão das microbacias, evitando o curso d'água, sempre que possível na UPA. 2

A especificações das estradas principais tem por largura de 12 metros, sendo 06 metros de leito carroçável e 06 metros de faixa de domínio com abertura de 03 metros para cada lateral, essas estradas são construídas com larguras menores (em média de 6 a 8 metros), de acordo com o planejamento na UPA 14, estão projetados a construção de 31,05 km de estradas primárias.

Já as estradas secundárias servem de acesso as UCA's e UT's onde foi construído os pátios de estocagem, com leito carroçável de até 5 metros a 2 metros para cada lateral, total de 9 metros, tendo uma área de 77,76 km de estradas secundárias.

Os pátios de estocagem servem para armazenamento das toras e foram projetados para UPA 14 de 258 pátios no tamanho de 20x50m totalizando 12,09 hectares.

2.3 Infraestrutura de exploração

Os maquinários e equipamentos que foram utilizados durante a operação das atividades na área de manejo florestal e transporte de toras para o pátio pulmão e pátio da indústria na sede do município de Manoel Urbano estão descritas no Plano de manejo florestal seguindo as leis e instruções Normativas/IBAMA e MMA no 07/2003, 05/2006 e 01/2015 Resolução CONAMA 406/2009. De acordo com o plano de manejo, a área aberta foi de 134 ha. Os ramais principais tiveram largura máxima de 4,90 metros, considerando

1,5 m a mais da largura da máquina de arraste, conforme determinava o Manual de Vistoria de Campo para Planos de Manejo Florestal Madeireiro na Amazônia.

O conjunto de dados de campo foram coletados durante a exploração florestal da UPA-14 do plano de manejo florestal da Agro cortex obtidos por Inácio (2021), onde os vetores de estrada e do pátio de estocagem de madeira foram coletados *in loco* no dia 26/09/2020 (Figura 02), com uso do receptor Garmin GPS 76CSX, e foram utilizados nesse estudo para avaliar a acurácia do mapeamento das alterações na cobertura florestal.




Figura 2 - Infraestrutura de exploração na Unidade de Produção Anual nº 14 do Plano de Manejo Florestal da Agro cortex Madeiras do Acre LTDA. Fonte dados de campo: INÁCIO, 2021.

Dentro no dimensionamento da exploração que foi realizada de modo tradicional realizado o levantamento, da UPA-14 AS UT's com área efetiva de exploração (AEE) em média de 78,168 hectares, a volumetria proposta para corte de 42.075,4804 m³, tendo um total de 3.584 árvores com media volumétrica de 11,74 m³ por arvore e 8,28 m³ por hectares (POA, 2020)

2.4 Imagens Sentinel e PlanetScope

Para analisar os impactos à vegetação decorrentes da exploração florestal na UPA-14 foram usadas as imagens do PlanetScope, Sentine-2 e Sentinel-1(Tabela 1). Para o Sentinel-2, considerou-se a cena na órbita-ponto 002-066, com máximo de cobertura de nuvens até 10%.

Para a realização da análise, usou-se cenas nos meses de outubro de dois anos consecutivos: 10/2019, 10/2020. Essas datas foram selecionadas por serem de antes da exploração (10/2019) e imediatamente após a conclusão da atividade de exploração florestal (10/2020).

Tabela 1 - Dados de obtenção das imagens

Satélite	Ano das Imagens	Dados Sensor	Resolução espacial
Planet & NICFI	2019/2020	Blue	4,77 m
		Green	
		Red	
Sentinel-1	2019/2020	VV+VH	10 m
Sentinel - 2	2019/2020	Red	10 m
		NIR (infravermelho próximo)	

As imagens da missão Sentinel foram utilizadas para obter identificação das estradas e pátios decorrentes da exploração florestal e as imagens PlanetScope como auxiliar na validação do mapeamento, devido a resolução espacial mais fina. As características dos sensores são descritas a seguir.

O Sentinel-1 faz parte de uma missão de Radar de Abertura Sintética (SAR), lançado em 2014, pela iniciativa conjunta Copernicus da Comissão Europeia (CE) e da Agência Espacial Europeia (ESA), com uma constelação de dois satélites idênticos, Sentinel-1A e Sentinel-1B, lançados separadamente.

O Sentinel-1 opera na banda-C com frequência de 5.4 GHz, com polarização VV e VH, adquiridas pelo modo Faixa Ampla Interferométrica ou Interferometric Wide (IW).

O modo IW adquire dados com uma faixa de 250 km com resolução espacial de 5 m por 20 m (visualização única) e captura três subfaixas usando a Observação do Terreno com Varreduras Progressivas SAR (TOPSAR). Com a técnica TOPSAR, além de direcionar o feixe no alcance como no ScanSAR, o feixe também é direcionado eletronicamente de trás para frente na direção do azimute para cada rajada, resultando em qualidade de imagem homogênea em toda a faixa imageada.

Os produtos de dados Sentinel-1 são disponibilizados sistematicamente e de forma gratuita para todos os usuários de dados, incluindo os usuários públicos, científicos e comerciais na plataforma GEE pela coleção “COPERNICUS/S1_GRD_FLOAT” do GEE e já pré-processados (Google Earth Engine, 2023a).

A missão Sentinel-2 é parte do programa Copernicus da Agência Espacial Europeia (ESA), que visa monitorar a variabilidade das condições da superfície terrestre. Através desta missão, os pesquisadores podem obter informações valiosas sobre a qualidade da vegetação com NDVI, o estado dos recursos hídricos e muito mais (Dos Santos *et al.*, 2022; Zhang *et al.*, 2022; European Space Agency, 2023).

A missão Sentinel-2 (S2) é uma iniciativa inovadora que oferece imagens multiespectrais de alta resolução com uma ampla faixa de cobertura. Com uma frequência global de revisita de 5 dias, esta missão permite um monitoramento contínuo e atualizado da superfície terrestre (Dos Santos *et al.*, 2022; European Space Agency, 2023).

O Instrumento Multiespectral S2 (MSI) é equipado com 13 bandas espectrais, cada uma otimizada para capturar diferentes características da superfície terrestre. As bandas espectrais da região do Visível e Infravermelho Próximo (NIR) tem resolução espacial de 10 metros e são especialmente úteis para monitorar a vegetação, pois as plantas saudáveis refletem fortemente a luz nessas faixas do espectro.

A coleção de imagens PlanetScope é um recurso valioso para o monitoramento contínuo das regiões tropicais por meio de satélites de alta resolução (Rehman *et al.*, 2023), além disso, essas imagens contribuem significativamente para as ações contra o desmatamento possibilitando suporte para gerar o mapeamento, e assim aplicar a detecção das áreas necessárias para impulsionar o processo de regeneração, restauração e enriquecimento com espécies florestais.

Os mosaicos NICFI - Norway's International Climate and Forest Initiative incluem tanto conjuntos mensais, quanto semestrais, as imagens têm uma resolução espacial de 4,77 metros. A identificação do tipo de mosaico é registrada no campo de metadados da imagem, denominado 'cadência'. Ao utilizar este campo em conjunto com as datas de início e término de cada mosaico, é possível efetuar a localização das imagens desejadas de forma precisa (Mauya *et al.*, 2022; Planet Team, 2017).

2.5 Google Earth Engine (GEE)

As ferramentas do geoprocessamento são essenciais para os serviços florestais, assegurando o desenvolvimento sustentável da floresta e seu monitoramento (Santos *et al.*, 2012). O Google Earth Engine (GEE) é uma plataforma de código aberto que tem uma série gratuita de dados de satélites, podendo ser utilizada para aquisição de imagens,

processamento e análise de um grande conjunto de dados para tomada de decisões (Mutanga & Kumar, 2019).

A plataforma GEE tem por finalidade disponibilizar uma ferramenta de processamento de imagens de larga escala capaz de atribuir versatilidade e rapidez por estar disponível acesso a plataforma de modo gratuito e conexão em nuvem com superprocessadores capazes de acessar o banco de dados petabyte de imagens de sensoriamento remoto (Tamiminia *et al.*, 2020).

A atualização diária do banco de dados de imagens do *Google Earth Engine* está disponível 24h, com constante atualização, recebendo uma taxa de 6000 cenas por dia de todas as missões ativas na órbita terrestre (Gorelick *et al.*, 2017). O formato do programa em nuvem promove uma segurança no processamento dos dados, diminuindo o risco da perda dos dados, facilitando a solução de problemas de alta capacidade de dados mássicos, com uso de algoritmos complexos em linguagem computacional (Gregory *et al.*, 2015).

O GEE é composto por uma vasta coleção de dados geoespaciais pré-processados, onde podem ser aplicados para desenvolver análises geoespaciais utilizando algoritmos de programação desenvolvidos na plataforma GEE (Flores-Anderson *et al.*, 2019).

A aplicação de códigos desenvolvido no GEE seguiu a estrutura descrita em Anexos, onde o código *JavaScript* se estrutura funções de variáveis (*var*), coleções de imagens de satélites (*ee.ImageCollection*), filtros (*ee.filter*) referente aos dados da variável, entre outras funções aplicadas, conforma exemplificado na figura 03.

```

4 // Load Sentinel-1 C-band SAR Ground Range collection (log scale, VV, descend:
5 var collectionVV = ee.ImageCollection('COPERNICUS/S1_GRD')
6 .filter(ee.Filter.eq('instrumentMode', 'IW'))
7 .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
8 .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
9 .filterMetadata('resolution_meters', 'equals', 10)
10 .filterBounds(roi2)
11 .map(function(image){return image.clip(roi2)})
12 .select('VV')
13
14 print(collectionVV, 'S1_Collection VV');
15

```

Figura 3 - Script no site da plataforma GEE, para carregar imagem SAR. Fonte: autor.

2.6 Pré-processamento das imagens SAR

O GEE disponibiliza as imagens GRD do Sentinel-1 pré-processadas para derivar o coeficiente de retroespalhamento incluindo a aplicação do arquivo de órbita, a remoção de ruído de borda, remoção de ruído térmico, calibração radiométrica e correção de terreno (ortorretificação) (Google Earth Engine, 2023a).

O arquivo de órbita, gerado pelos serviços Copernicus, atualiza os metadados da órbita do satélite. É feito a remoção de ruído de baixa intensidade e dados inválidos nas bordas da

cena. A remoção do ruído térmico consiste em remover ruído aditivo reduzindo as descontinuidades entre os subfaixas das cenas. Na calibração radiométrica ocorre a conversão dos valores de pixel da imagem de número digital (ND) para coeficiente de retroespalhamento (σ°) em decibéis (dB), via escala logarítmica ($10 \cdot \log_{10}(x)$), conforme equações 1 e 2 descritas na tabela 02:

Tabela 2 - Equações de conversão de dados SAR

Índice	Fórmula	Referência	Equação
VD	$10^{\sigma^\circ (dB)/10}$	MEYER, 2019	01
$\sigma^\circ (dB)$	$10 * \log_{10}(x)$	MEYER, 2019	02

Dados: Equação 01: (VD) Transformadas em base logarítmica (MEYER, 2019). **Equação 02:** Conversão de potência para a escala de decibéis logarítmicos (dB). (σ°) dados de retroespalhamento SAR de dados corrigidos radiometricamente do terreno. Números digitais (VD). escala linear em decibéis (dB) (FONTE: MEYER, 2019).

Na etapa de correção do terreno é usado o SRTM com resolução de 30 m ou ASTER para: I. Remover as distorções radiométricas dependentes da geometria; II. Normalizar o retroespalhamento medido em relação à inclinação do terreno; III. Remover as distorções geométricas como sobreposição e sombreamento e IV. Ajustar a imagem a um sistema de coordenadas geográficas.

2.7 Processamento e análise de imagens SAR

O método de processamento aplicado seguiu um script desenvolvido por Flores-Anderson *et al.*, (2019) e por Podest *et al.* (2020), usando as imagens Sentinel-1A para identificar a diferença na cobertura vegetal antes e após o desmatamento. O script foi desenvolvido com o objetivo de detectar a alteração multivariada das imagens bitemporais que irá atribuir a diferença do retroespalhamento ligada ao desmatamento. Segundo Flores-Anderson *et al.*, (2019), esse tipo de alteração é mais fácil de detectar com dados bitemporais.

Primeiramente, carregou-se a Coleção de Imagens Sentinel-1 com polarização descendente VV e VH. As imagens foram filtradas de acordo com diversas propriedades, como o modo do instrumento, polarização, passagem de órbita, resolução espacial, região de interesse (ROI) e as datas desejadas.

A sequência de filtragem seguiu as seguintes etapas:

- I. Carregar-se a coleção de imagens do satélite Sentinel-1 no modo Ground Range Detected (GRD).

- II. Filtrar-se a coleção para incluir apenas imagens que possuem polarização vertical-vertical (VV) e vertical-horizontal (VH).
- III. Filtrar-se a coleção para incluir apenas imagens capturadas no modo de imagem interferométrica de banda larga (IW).
- IV. Filtrar-se a coleção para incluir apenas imagens capturadas em uma órbita descendente.
- V. Filtrar-se a coleção para incluir apenas imagens com resolução espacial de 10 metros.
- VI. Aplicar-se uma função a cada imagem na coleção para recortar a imagem à região de interesse definida pela variável `UPA14`.
- VII. Filtrar-se a coleção para incluir apenas imagens capturadas entre 1º de maio e 1º de novembro de 2019.
- VIII. Filtrar-se a coleção para incluir apenas imagens capturadas entre os meses de agosto e novembro de 2020.

A etapa seguinte foi a filtragem do ruído Speckle, componente fundamental do processo de suavização de imagens de radar de abertura sintética (SAR). Seu objetivo é reduzir o ruído granular, conhecido como Speckle, tornando as imagens SAR mais claras e adequadas para análises posteriores. Para eliminar esse ruído, aplicou-se um tipo de filtro de média móvel adaptativa projetado para preservar bordas e características significativas da imagem enquanto suaviza áreas de ruído (Lee *et al.*, 2003).

Depois das imagens filtradas foi realizado o cálculo da razão entre as imagens de 2019 e 2020 com o objetivo de identificar as diferenças no retroespalhamento devido as alterações na cobertura vegetal.

Foram calculados a média e o desvio padrão da imagem razão e em seguida selecionou-se um valor limiar aplicado ao desvio padrão. Esse valor limiar foi então usado para aplicar uma máscara nas imagens, permitindo a identificação da perda de vegetação ocorrida entre as imagens bitemporais analisadas.

As imagens processadas foram então exportadas para o software QGIS 3.22, para a conversão do formato raster para vetor e posteriormente efetuado o cálculo das áreas impactadas pela exploração florestal.

Neste trabalho, utilizamos também índices de vegetação para analisar a cobertura vegetal na UPA-14, foi utilizado dois índices de vegetação SAR e Ópticos. Os índices de vegetação são obtidos a partir do processamento de diversas bandas de dados ópticos, proporcionando um realce que permite uma análise mais precisa da vegetação (Watzlawick *et al.*, 2009; Meneses & Almeida, 2012).

Após identificar as áreas onde ocorreu perda de vegetação, realizou-se uma comparação entre os dados oriundos de campo de Inácio (2021), da análise das imagens do Sentinel-2 e Planet dos anos antes e após a extração da madeira (2019 e 2020). O objetivo dessa comparação foi determinar a diferença na cobertura vegetal entre esses anos. Essa diferença foi então usada para avaliar o desempenho da detecção dos dados SAR.

2.8 Processamento e análise de imagens ópticas

O uso de imagens do satélite Sentinel-2 na criação de mapas é uma prática comum e valiosa em diversos campos, como monitoramento ambiental, gestão de recursos naturais e planejamento urbano. A aquisição de dados da coleção de imagens Sentinel-2 "COPERNICUS/S2_HARMONIZED" (Google Earth Engine, 2023b) foi realizada no GEE, onde foi aplicado um filtro para selecionar imagens com uma porcentagem de pixels nublados menor ou igual a 1%, a fim de minimizar a influência de nuvens na análise. Posteriormente foi executado o recorte das imagens da coleção para a UPA14.

A segunda etapa foi a filtragem das imagens para o período de outubro a novembro de 2020, período que coincide com o final da exploração florestal. A terceira fase foi a criação da imagem média para o ano de 2020. Isso é realizado com a aplicação de um redutor que calcula o valor mínimo em cada pixel de todas as imagens na coleção. A imagem média resultante é útil para analisar tendências de longo prazo na área de estudo e identificar mudanças significativas na cobertura terrestre.

A coleção PlanetScope foi importada pela função 'ee.ImageCollection' pelo GEE, mais primeiro para ser baixada foi necessário fazer um cadastro no site <<https://www.planet.com/>> para gerar um ID de acesso no Google Earth Engine, por meio da coleção de imagens presentes no GEE, foi selecionada a área de interesse na UPA-14.

Após a filtragem das características da imagem planet e das propriedades da imagem, definição para selecionar imagens com baixa presença de nuvens, filtragem das imagens pela data, no caso os respectivos anos de 2019 e 2020, a classificação da imagem para gerar um índice de vegetação 'NDVI', onde utiliza duas bandas NIR (*Near Infrared*) e R (*red*), e seguir etapas de composição das bandas RGB (*Red, Green e Blue*). Após a visualização foi feito a exportação das imagens para o Google Drive, para após serem baixadas e trabalhadas no Qgis.

Posteriormente foi calculado o índice de vegetação NDVI (tabela 3) ou *Normalized Difference Vegetation Index* (NDVI) (Sarzynski, *et al.*, 2020) para identificar e quantificar as alterações na vegetação, o NDVI varia de -1 a 1 e está diretamente relacionado com o

vigor da vegetação, valores mais altos indicam vegetação mais vigorosa, valores próximos a 0 indicam solo exposto e/ou áreas urbanas e valores negativos a presença de água.

Tabela 3 - Índice de vegetação aplicado a imagens Sentinel-2 e Planet

Índice	Fórmula	Referência
NDVI	$\frac{NIR - R}{NIR + R}$	Rouse et al., 1973
X	$(média2019 - média2020).lt(1.2)$	Santos, et al., 2008

Dados: NIR (Near Infrared): Esta é a banda do infravermelho próximo. R (Red): Esta é a banda do vermelho.

2.9 Validação do Mapeamento

A etapa de validação do mapeamento usou como referência dados de campo levantados por Inácio (2021) e imagem Planet para as classes de pátio, estradas e floresta, totalizando setenta e cinco pontos aleatórios dentro da área de estudo.

Para verificar a acurácia da classificação (dados preditos) em comparação com os dados de referência (informações reais) foi utilizada a matriz de erro, também chamada de matriz de confusão ou tabela de contingência (Congalton et al., 1991).

A matriz de erro é uma matriz quadrada de dimensão $n \times n$, em que n é o número de classes. As colunas da matriz representam os dados de referência, enquanto as linhas indicam os dados classificados pelo algoritmo de classificação. A diagonal principal indica a concordância entre estes dois grupos de dados. A exatidão global é calculada pela divisão da soma dos elementos da diagonal principal pelo número total de amostras tomadas, conforme a seguinte expressão:

$$P_o = \frac{\sum_{i=1}^m n_{ij}}{N}$$

em que:

P_o = exatidão global do mapeamento;

N = número total de unidades amostrais;

n_{ij} = total de elementos da diagonal principal, ou seja, número de pixels corretamente classificados;

m = número de classes ou categorias presentes na matriz de erro; e

i e j = linhas e colunas da matriz de erro, respectivamente.

O cálculo da matriz de confusão foi realizado no plugin AcATaMa, onde foi obtido a exatidão global, acurácia do usuário, acurácia do produtor.

Para a validação dos mapas foi utilizado também o Coeficiente de Concordância Kappa, por sua vez, é uma medida estatística que avalia a precisão da classificação, levando em consideração a possibilidade de acerto aleatório conforme Congalton & Green (2008).

O cálculo do coeficiente Kappa é feito de acordo com as seguintes equações:

$$K = \frac{P_o - P_c}{1 - P_c}, \quad P_o = \frac{\sum_{i=1}^M n_{ij}}{N},$$

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2}.$$

sendo:

P_o = exatidão global;

P_c = proporção de unidades que concordam por casualidade;

M = número de classes presentes na matriz de erro;

n_{ij} = número de observações na linha i e coluna j ;

n_{i+} e n_{+i} = totais marginais da linha i e da coluna j , respectivamente; e

N = número total de unidades amostrais contempladas pela matriz.

Os valores de Kappa variam de 0 a 1, onde 1 indica uma concordância perfeita entre as classificações previstas e reais, 0 indica uma concordância não melhor do que o acaso.

O valor de Kappa (K) pode ser comparado como os valores e conceitos contidos na Tabela 04, desenvolvidos por Landis & Koch (1977) para o mapeamento.

Tabela 4 - Conceitos do coeficiente de concordância Kappa

Valor de K	Qualidade da classificação
<0,0	Péssima
0,0 - 0,2	Ruim
0,2 - 0,4	Razoável
0,4 - 0,6	Boa
0,6 - 0,8	Muito boa
0,8 - 1,0	Excelente

Fonte: Adaptada de Landis & Koch (1977).

O cálculo de Kappa foi realizado no plugin SCP- Semi-Automatic Classification Plugin.

3 Resultados

A aplicação do filtro reduziu o ruído *Speckle* nas imagens SAR de 2019 e 2020 (Figura 04), etapa fundamental para a análise dos dados nas imagens bitemporais. No entanto, apesar da redução do efeito granulado, não realçou visualmente a abertura das estradas florestais, dos pátios de estocagem de madeira e das clareiras nos dados SAR de outubro de 2020, ao final exploração florestal na UPA-14.




Figura 04 - Imagem do Sentinel-1 de 2019 e 2020, sem filtragem do ruído Speckle (à esquerda) e com a filtragem do ruído Speckle (à direita) com destaque da UPA-14 (polígono branco).

Na área da UPA-14 destacada na imagem SAR do Sentinel-1 (Figura 04), evidenciou que os dados de SAR têm uma sensibilidade com o aspecto do relevo do solo. Ao contrário,

as maiores alterações na cobertura florestal ocasionada pela abertura de estradas não foram identificadas nas imagens de 2020.

Ao analisar os histogramas das imagens SAR, que exibem a dispersão da frequência dos valores de retroespalhamento das bandas VV e VH da região da área de estudo (figura 05), nos anos de 2019 e 2020, antes e depois da exploração florestal, respectivamente, foi observado que não houve uma grande variação de valores de retroespalhamento nas imagens bitemporais.




Figura 05 - Histogramas das imagens Sentinel-1 com polarização VV e VH da UPA-14 nos anos de 2019 e de 2020.

No ano de 2019, nos dados Sentinel-1 com polarização VV, foi observado o valor mínimo de retroespalhamento de -9,654 dB e o máximo de -5,622 dB. Nesse ano, na banda com polarização VH, o intervalo de valores de retroespalhamento foi de -15,451 dB a -12,020 dB.

Os valores de retroespalhamento na imagem do ano de 2020 tem uma amplitude de valores mínimos e máximo, na banda com polarização VV, de -8,940 dB a -5,058 dB, e na polarização VH os dados foram de mínimo -15,454 dB e máximo -10,983 dB.

Assim, o retroespalhamento observado nas imagens SAR nos anos de 2019 e 2020, possuem valores similares na região da UPA-14, tornando a identificação das alterações no dossel uma tarefa difícil. O resultado do p-valor foi de 0,91% com o nível de confiança de

95%, mostrando que não há diferença significativa entre as médias das polarizações VV e VH dos anos de 2019 e 2020.

A aplicação da metodologia desenvolvida por Flores-Anderson *et al.*, (2019) com o uso dos dados Sentinel-1 no mapeamento da degradação florestal da UPA-14, não se obteve resultados satisfatório na identificação das pequenas aberturas no dossel oriundas da exploração florestal em área manejada.

A metodologia parece mais eficiente para identificar as áreas que sofreram alterações de desmatamento ou retirada da vegetação, como acontece na supressão da floresta para formação de pastagem. A Figura 05 ilustra a aplicação da metodologia de Flores-Anderson *et al.*, (2019) em área próxima da área de estudo, com destaque na cor vermelha para as alterações da cobertura florestal, onde o método aplicado na detecção do manejo não teve bom resultado, por ser analisado área aberta menor.




Figura 4 - (A1) Imagem diferença entre 2019 a 2020; (A2) Classificação mascara das alterações na vegetação entre os anos de 2019 a 2020.

A Figura 06, destaca uma área da UPA-14 onde se observa visualmente nas imagens ópticas dos satélites PlanetScope e Sentinel-2 as mudanças na vegetação ocorridas entre os anos de 2019 e 2020, evidenciando que a exploração foi iniciada no ano de 2020. É possível identificar o padrão característico da abertura das estradas florestais nessas imagens.

Os dados do Sentinel-1, banda C, tem baixa resposta na percepção visual de alterações na vegetação de pequenas áreas dentro da floresta, por ser tratar de um ambiente homogêneo com predominância de retroespalhamento volumétrico.




Figura 06 – Imagens dos satélites Sentinel-1 nas bandas VV e VH em escala de cinza, PlanetScope e Sentinel-2 em composição colorida RGB, de 2019 e de 2020, recortadas para uma parte da UPA-14.

A razão entre as imagens de 2019 e 2020, para serem melhores interpretados foram alterados e categorizados pela função (.lt), aplicando uma função de limiar com valor de 1,3 menor que 1.3)(Figura 07 e Figura 08), pois estudos mostram que a seleção de um limiar

favorece a segmentação de valores específicos e assim a possibilidade de classificar alvos na superfície (MoharramI *et al.*, 2021; Koo *et al.*, 2023).

As Figuras 07 e 08, mostra a imagem diferença binarizada com polarização VH e VV, onde não foi possível detectar o padrão típico das alterações à cobertura florestal decorrentes da abertura das estradas florestais, pátios de estocagem de madeira e clareiras.




Figura 07 - Imagem binária da diferença da média das bandas com polarização VH, anos de 2019 e 2020.




Figura 08 - Imagem binária da diferença da média das bandas com polarização VV, anos de 2019 e 2020

Na composição colorida falsa cor com as imagens subtração com polarização VV, VH e os valores de ângulo (*angle*) (Ângulo de incidência aproximado do elipsóide) (Figura 09) permitiu identificar parte da abertura das estradas utilizadas no manejo florestal, no entanto, as áreas abertas estão pouco definidas, em comparação com as imagens dos satélites PlanetScope e Sentinel-2 (Figura 6), provavelmente influenciado pela rugosidade do terreno e outros fatores que interferem no retroespalhamento das ondas do radar devido algumas limitações da banda C.




Figura 09 - Composição SAR, SENTINEL-1, bandas VV, VH, diferença entre os anos 2019 e 2020.

Na imagem da composição RGB referente a subtração das imagens SAR dos anos de 2019 e 2020 (Figura 09), é possível verificar vestígios das alterações no dossel nas regiões mais claras, que estão distribuídas como as estradas principais. Nessa composição RGB, os tons da cor verde mais claro podem indicar a infraestrutura da exploração florestal e os tons da cor verde mais escuros, as áreas de floresta. No entanto, a definição das áreas abertas para o manejo está pouco nítida na figura 09, em comparação com as imagens do Sentinel-2 (Figura 11).

O script desenvolvido para criar a imagem da figura 10, foi a subtração dos dados das médias das imagens de 2019 para 2020, e assim foi aplicado um valor limiar que corresponde a valores menores que 1.3, o limiar define valores maiores que 1.3 são nulos (0) e valores igual ou menor que 1.3 verdadeiros iguais a 1, que corresponde a tornar a imagem binarizada. A aplicação tem por objetivo o quantitativo das áreas abertas pela infraestrutura do manejo florestal por meio da escolha dos valores do pixel do intervalo correspondente as infraestruturas de estradas e pátios, nas imagens Planet é possível identificar em alguns pontos da estrada principal e secundaria, já na imagem do Sentinel-1 a figura 10 mostra composição colorida do SAR, o ruído da imagem em certos pontos concentrações de pontos azuis, na região de estradas principais e difícil identificar, devido algumas limitações da banda C, com as frequências VV/VH e ângulo do satélite.




Figura 10 - Compositor colorido dados binarizados de imagem Sentinel-1, frequências VV+VH do ano de 2019 para 2020.

A composição da imagem SAR do Sentinel-1, com a divisão das polarizações VV e VH definidas por cada banda da imagem apresentam aspectos visuais diferentes da imagem SAR na figura 07 e figura 08, por apresentar composição de imagem colorida, aspectos buscados para ser possível a identificação visual da abertura de estradas por meio da subtração das imagens SAR, para que os valores de 2020 se sobressai na imagem, destacando

os pontos azuis e vermelhos, seguindo o conceito que as alterações desenvolvidas no manejo para o respectivo ano de 2020 estaria sendo destacado.

O método aplicado na figura 10 buscou destacar as áreas abertas dentro da floresta, onde é possível visualizar vestígios da arquitetura das estradas (linhas contínuas). No entanto, a falta de nitidez ao segmentar somente as áreas alteradas faz com que a imagem mostre pontos em toda a área. Isso ocorre por conta do efeito Speckle das bandas VV e VH, o que superestima a imagem devido ao retroespalhamento do pixel, tornando difícil a identificação nítida a olho nu, como na imagem SAR.

O uso e aplicação da imagem óptica do Sentinel-2 na classificação da área impactada de manejo, permitiu mapear as estradas florestais, pátios e clareiras oriundas da exploração madeireira (Figura 11). A imagem binária (Figura 11-01) destaca, na cor branca, as áreas abertas pelo manejo florestal, que após a vetorização, permitiu o cálculo do impacto à vegetação.

A composição RGB da imagem NDVI (Figura 11-02), destacou também as alterações na cobertura florestal, permitindo identificar onde ocorreu o maior impacto à vegetação da UPA-14, com destaque as áreas de solo exposto na cor vermelha, tendo um levantamento de 183,49 ha nas imagens do Sentinel-2.




Figura 11- (01) Imagem Sentinel-2 do ano de 2020 binarizada, preto e branco; (02) Imagem Sentinel-2 classificada em composição NDVI, do ano de 2020.

A imagem Planet também mostrou grande potencial na detecção da exploração florestal, a exemplo do mosaico do ano de 2020, na área da UPA-14 (Figura 12), com resolução espacial mais fina (4,77 m) em comparação com Sentinel-1 e Sentinel-2 (10m),

porém de uso mais restrito, por isso foi usada com imagem referência na validação do mapeamento.




Figura 12- Imagem PlanetScope da UPA-14, mosaico do mês 09 de 2020.

Na comparação dos resultados referente à detecção das estradas florestais a partir das imagens de mesma resolução espacial de 10 m, o Sentinel-1 e do Sentinel-2, o uso dos dados do Sentinel-2 teve maior aproximação em relação a imagem referência do Planet.

Ambos os satélites tem sua utilidade para o monitoramento ambiental, porém os resultados de identificação das estradas e pátios do manejo nos diferentes tipos de sensores ativo e passivo (Figura 13), apresentaram resultados bem diferentes, predominando um efeito difuso, do tipo “sal e pimenta” ou com aspecto do ruído Speckle, no processamento das imagens SAR.

As imagens derivadas do satélite Sentinel-2 foi a que obteve maior precisão, com equivalente a 3,11% em área da UPA, na identificação da infraestrutura das estradas florestais, em comparação com a imagem Planet (figura 13) com 2,62% e a maior extensão de área explorada na UPA-14 (Tabela 5).




Figura 13 - Imagens referente a área amostral da UPA-14, destaca as estradas e pátios implementados pelo Manejo florestal, dos satélites Sentinel-1, Sentinel-2 e Planet do ano de 2020.

Tabela 5 – Área mapeada de abertura das estradas e pátios na UPA-14 do manejo florestal da Agro cortex, explorada no ano de 2020.

Fonte	Área mapeada (ha)	Área da UPA-14 (%)
Áreas de infraestrutura (POA)	117,00	1,98%
PlanetScope	154,38	2,62%
Sentinel-1	85,56	1,44%
Sentinel - 2	183,49	3,11%

Os resultados mostram que o mapeamento das estradas florestais e pátios usando as imagens do Sentinel-2 tem maior área de exploração do que a área que consta no relatório do manejo florestal, que é 117 ha, e com maior acurácia em relação à detecção usando o Sentinel-1, como evidenciado na tabela 06 e tabela 07, que apresentam a matriz de confusão e estatísticas derivadas, para a classificação usando os dados do Sentinel-1 e Sentinel-2, respectivamente.

Tabela 6 - Matrix de Confusão classificação Imagem Sentinel-1.

Mapa temático	1(Floresta)	2(Estrada)	3 (Pátio)	Total	Acurácia do usuário
1 (Floresta)	23	2	0	25	92%
2 (Estrada)	12	12	1	25	48%
3 (Pátio)	1	12	12	25	48%
Total	36	26	13	75	
Acurácia do Produtor	63,8%	46,1%	92,3%		
Exatidão Global	62,6%				
Índice Kappa	0,44				

Tabela 7 - Matrix de Confusão classificação Imagem Sentinel-2.

Mapa temático	1 (Floresta)	2 (Estrada)	3 (Pátio)	Total	Acurácia do Usuário
1 (Floresta)	23	2	0	25	96%
2 (Estrada)	1	24	0	25	88%
3 (Pátio)	2	9	14	25	68%
Total	26	35	14	75	
Acurácia do produtor	88,4%	68,5%	100%		
Exatidão Global	81,3%				
Índice Kappa	0,72				

Tabela 8 - Matrix de Confusão classificação Imagem PlanetScope.

Mapa temático	1(Floresta)	2(Estrada)	3(Pátio)	Total	Acurácia do Usuário
1(floresta)	24	1	0	25	96%
2(estrada)	3	22	0	25	88%
3 (Pátio)	0	8	17	25	68%
Total	27	31	17	75	
Acurácia do produtor	89%	70,9%	100%		
Exatidão Global	84%				
Índice Kappa	0,76				

A acurácia por classe de mapeamento indica que a classificação a maior acurácia foi observada para floresta, especialmente com os dados do Sentinel-2, com uma acurácia do usuário e do produtor acima de 88%.

Para as estradas florestais, usando as imagens SAR a acurácia ficou em média 48%, subestimando a classe, porém vale destacar que a confusão ocorreu com o mapeamento dos pátios de estocagem de madeira (Tabela 6). Para o pátio, a acurácia do produtor alcançou mais de 92% com o uso dos sensores ativo e passivo, considerado um resultado satisfatório.

Os maiores erros de classificação com o Sentinel-1 são referentes à distinção entre a classe de floresta e as estradas florestais e pátios, com erros de comissão, que mede a confiabilidade de uma classe corresponder à verdade de campo, na ordem 36%.

Em geral, a acurácia da classificação com imagem Sentinel-2 foi maior exatidão global de 81,3% e Kappa 0,72 (Tabela 07), já os resultados do Sentinel-1 o índice Kappa foi de 0,44. Os maiores erros de classificação ocorreram entre estradas e pátios, portanto na infraestrutura do manejo, assim o mapeamento das infraestruturas da exploração foi observado com Sentinel-2, e mais satisfatório as imagens do Planet (Tabela 08), com melhores dados quantitativos e sua representação visual.

4 Discussão

Os dados encontrados por meio dos sensores ativos e passivos mostram uma diferença nas características das potencialidades de cada sensor na detecção do manejo, onde sensor ativo encontrou baixa qualidade em comparação aos sensores passivos por meio da comparação da resposta das informações nas imagens da área de manejo.

Os resultados obtidos no monitoramento pós-extração de madeira do manejo florestal, por meio das imagens de sensoriamento remoto é uma alternativa para grandes áreas e regiões de difícil acesso. Os sensores ópticos, que utilizam a radiação solar e a sua interação com os alvos terrestres na coleta de dados, sofrem interferência da cobertura de nuvens e fumaça, comuns na Amazônia. Diante disso, destacamos a importância do uso de dados dos radares, porém, o uso das imagens SAR na Amazônia é desafiador segundo Watanabe, *et al.*, (2021)

A detecção das estradas florestais na área manejada usando o Sentinel-1 teve menor acurácia (46,1%) que usando o Sentinel-2 (68,5%). Na visualização das imagens Sentinel-1, antes e após o processamento dos dados, não foi uma tarefa fácil identificar os locais que foram manejados, mesmo a imagem SAR apresentando uma resolução espacial de 10m, possivelmente pelo efeito combinado de vários fatores, como por exemplo, o sombreamento e características da floresta, as características do sensor de visada lateral e banda C, podendo ter implicação na penetração das ondas de radar nas estradas e áreas abertas pela exploração florestal. Além disso, a seleção do algoritmo de classificação e o espaço temporal utilizado devem ser considerados também.

Estudos que utilizaram a imagem SAR evidenciam que a banda C tende a ser menos eficiente para captar pequenas alterações na vegetação, por limitações relacionadas ao retroespalhamento das ondas SAR que são captadas pelo sensor (Jesus & Kuplich, *et al.*, 2021). De fato, os resultados alcançados na área da UPA-14, revelaram que os dados da

banda C do Sentinel-1 tiveram baixa sensibilidade em detectar as alterações na cobertura florestal em área de exploração sob regime de manejo florestal. Nessas imagens, o retroespalhamento em áreas de florestas se dá por dispersão volumétrica da copa das árvores, uma superfície rugosa, e as pequenas aberturas no dossel não alteraram o comportamento padrão ao ponto de detectar as mudanças na vegetação após a exploração madeireira, como observado nos histogramas das imagens bitemporais e nas imagens razão.

Por outro lado, Tanase *et al.* (2019) demonstraram, por meio de pesquisas conduzidas em uma floresta temperada, que o coeficiente de retroespalhamento na banda C revela sensibilidade ao volume das folhas, uma vez que é atenuado por ele. O retroespalhamento do radar é afetado pelo tipo de floresta e formas estruturais (tipo e orientação), condições ambientais (por exemplo, umidade e fenologia) e propriedades de imagem de radar, auxiliando no monitoramento florestal (Lee, *et al.*, 2003; Tanase, *et al.*, 2019).

A aplicação da metodologia desenvolvida por Flores-Anderson *et al.*, (2019) com o uso dos dados Sentinel-1 no mapeamento da degradação florestal da UPA-14, não se obteve resultados satisfatório na identificação das pequenas aberturas no dossel oriundas da exploração florestal em área manejada. A metodologia parece mais eficiente para identificar as áreas que sofreram alterações de desmatamento ou retirada da vegetação, como acontece na supressão da floresta para formação de pastagem. A Figura 13 ilustra a aplicação da metodologia de Flores-Anderson *et al.*, (2019) em área próxima da área de estudo, com destaque na cor vermelha para as alterações da cobertura florestal, onde o método aplicado na detecção do manejo não teve bom resultado, por ser analisado área aberta menor.

No entanto, vários estudos indicam as potencialidades do uso do Sentinel-1, incluindo para monitorar o crescimento florestal ao longo do tempo (Schardt *et al.*, 2020), indicando como os dados SAR podem ser usados para avaliar a dinâmica de crescimento das florestas. Nas simulações conduzidas pelos autores, foi observado que mudanças sutis, como a extração seletiva de madeira, não podem ser prontamente identificadas usando dados nas faixas de frequência C ou L obtidos por meio de aquisições intermitentes. Essa observação sugere a necessidade de uma frequência temporal mais alta para detectar esse tipo de perturbação (Lee, *et al.*, 2003; Tanase, *et al.*, 2019).

Segundo SARZYNSKI, *et al.*, 2020, as mudanças significativas, como o desmatamento total, podem ser obscurecidas devido a efeitos como inversão, resultado de uma resolução espacial inadequada em relação à altura da vegetação. Isso influencia os efeitos combinados de sombreamento e iluminação nas bordas das áreas desmatadas, destacando, ainda, a influência crucial da estrutura e altura da vegetação circundante na

capacidade de detecção na banda C. Por outro lado, estudos relacionados a combinação de imagens SAR da banda L, do satélite ALOS PALSAR-2, apresenta bom resultado em monitoramento da degradação florestal, já estudos que utilizam banda P (comprimento de onda de 70 cm), possibilita um potencial para monitoramento da degradação florestal (Ryan *et al.*, 2012; 2014).

Uma alternativa é a integração de dados SAR e imagens ópticas para melhorar a detecção de mudanças, em análises temporais das alterações da vegetação (Kuck *et al.*, 2021; Silva *et al.*, 2019; Ghorbanian, *et al.*, 2021; Matarira, *et al.*, 2022).

A combinação de sensores passivos e ativos na detecção das alterações da vegetação em área de floresta, pode reduzir os erros de omissão do mapeamento (Perbet, *et al.*, 2019; Matarira *et al.*, 2022; Meng *et al.*, 2023) e melhorar a acurácia na detecção de mudanças na cobertura e uso da terra (Tavus *et al.*, 2022; Kinnebrew *et al.*, 2022). A integração do Sentinel-1 e Sentinel-2 apresentou bons resultados na identificação da cobertura da vegetação litorânea na detecção de áreas menores que 100 metros quadrados (Liu *et al.*, 2022, Rao *et al* 2021).

As imagens de satélites ópticos proporcionam uma precisão melhor quando aplicado em áreas de manejo florestal, para identificar a infraestrutura de estradas e pátios, devido à sua capacidade de captar áreas que não são florestas dentro da área de manejo. Isso inclui a detecção de estradas secundárias e primárias, cujos dados coincidem com os dados de campo das estradas principais e secundárias. Essa correspondência demonstra a eficácia dessas imagens para o monitoramento do manejo florestal. Porém, a uso dos sensores ópticos se limita a uma pequena janela temporal na Amazônia, restrita ao período seco, devido as interferências atmosféricas.

Estudos com imagens SAR do sentinel-1, na banda C que aplicaram índice de vegetação RFDI e mRFDI com as polarizações HH, VH e VV, tiveram bons resultados na acurácia do usuário para classificação de floresta e água, e gerou muita confusão entre agricultura, vegetação secundária e floresta, com exatidão global considerada baixa (52%) (Nicolau *et al.*, 2021), corroborando com os resultados desse estudo que alcançou 63%, porém com menos classes de mapeamento.

Assim, há necessidade de mais estudos que utilize a integração de imagens SAR e ópticas, do mesmo modo como a utilização de outros métodos de classificação são imprescindíveis de serem avaliados, visando melhorar a detecção das mudanças na vegetação provocadas pela abertura de estradas e pátios do manejo florestal.

5 Conclusão

As imagens SAR, do Sentinel-1 teve um baixo potencial na detecção das áreas alteradas pelo manejo florestal pelo fato a aplicação ser realizada em uma área de Manejo florestal de baixo impacto.

Apesar das interferências atmosféricas dos sensores ópticos, o uso das imagens dos satélites PlanetScope e Sentinel-2 obtiveram maior precisão no mapeamento da infraestrutura da exploração florestal na área do manejo, destacando assim o potencial de uso desses sensores.

Conclui-se que o método de identificação da abertura de estradas florestais com sensores SAR e ópticos se faz necessários novos estudos que possibilite a integração dos sensores ativos e passivos para um melhor desempenho de resolução espacial, em áreas de manejo florestal com ocorrência de nuvens, por meio de scripts desenvolvidos no *Google Earth Engine* para identificar resultados mais precisos.

Referências Bibliográficas

- ACRE. Governo do Estado do Acre. Programa Estadual de Zoneamento Ecológico Econômico do Estado do Acre. *Zoneamento ecológico - econômico: recursos naturais e meio-ambiente*; documento final. Rio Branco: SECTMA, 2000. 178 p.
- ALVARES, Clayton Alcarde *et al.* *Köppen's climate classification map for Brazil*. Meteorologische zeitschrift, v. 22, n. 6, p. 711-728, 2013.
- AMARAL, E. F. do.; BARDALES, N. G.; PEREIRA, J. B. M.; GONÇALVES, R. C.; BERGO, C. L.; ARAÚJO, E. A. de; AMARAL, E. F. de; MELO, A. W. F. de. *Zoneamento pedoclimático para a seringueira e o café no município de Capixaba*. 2019. EMBRAPA, link de acesso: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1112991>>.
- ASNER, G. P. *Cloud cover in Landsat observations of the Brazilian Amazon*. International Journal of Remote Sensing, v. 22, n. 18, p. 3855–3862, 2001.
- BOULTON, C. A.; LENTON, T. M.; BOERS, N. *Pronounced loss of Amazon rainforest resilience since the early 2000s*. Nature Climate Change, v. 12, n. 3, p. 271-278, 2022.
- BRASIL. *Instrução Normativa nº 4 de 4 de março de 2002*. Dispõe sobre a Autorização Prévia à Análise Técnica de Plano de Manejo Florestal Sustentável-APAT, e dá outras providências. Disponível em: <<https://www.ibama.gov.br/sophia/cnia/legislacao/IBAMA/IN0004-040302.PDF>>. Acesso em: 05 fev. 2023.
- BRASIL. *Instrução normativa nº 5, de 11 de dezembro de 2006*. Dispõe sobre procedimentos técnicos para elaboração, apresentação, execução e avaliação técnica de Planos de Manejo Florestal Sustentável-PMFSs nas florestas primitivas e suas formas de sucessão na Amazônia Legal, e dá outras providências. Disponível em: <<https://www.ibama.gov.br/sophia/cnia/legislacao/MMA/IN0005-111206.PDF>>. Acesso em: 05 fev. 2023.
- BRASIL. *Lei nº 12.651, de 25 de maio de 2012*. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória no 2.166-67, de 24 de agosto de 2001; e dá outras providências. Diário Oficial da União, Brasília, DF, 28 mai. 2012.

- BRASIL. *Ministério da Saúde. Portaria nº 48, de 10 de julho de 1995*. Estabelece normas e procedimentos para a coleta, processamento, estocagem, distribuição e controle do fornecimento de sangue, seus componentes e hemoderivados, e dá outras providências. Diário Oficial da União, Brasília, DF, 11 jul. 1995. Seção 1, p. 12434. Disponível em: <<https://www.ibama.gov.br/sophia/cnia/legislacao/IBAMA/PT0048-100795.PDF>>
- CONGALTON, R. G.; GREEN, K. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 2. ed. New York: CRC Press, 2008. 183 p.
- CONGALTON, Russell G. *A review of assessing the accuracy of classifications of remotely sensed data*. Remote sensing of environment, v. 37, n. 1, p. 35-46, 1991.
- COSTA, S. S.; COSTA, J. A. L.; MACEDO, M. A.; CORREIA, M. R. D.; VIEIRA, A. M.; ROGERRIO, A. P. C.; SOARES, C. B. S. S.; BARROSO, C. M. SANSON, F. E. G.; SALLES, F. M.; PARISE, M.; FONSECA, M. G.; CAMPOS. M. A. A.; TEIXEIRA, W. F. *Operação Arco Verde: Análise do desmatamento por meio de imagens do SIPAM R99/SAR*. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 2011, INPE p.2997
- D' OLIVEIRA, M. V. N.; Broadbent, E. N.; OLIVEIRA, L.C.; ALMEIDA, D. R. A.; PAPA, A. D.; FERREIRA, M. E.; ZAMBRANO, A. M. A.; SILVA, C. A.; AVINO, F. S.; PRATA, G. A.; MELLO, R. A.; FIGUEIREDO, E. O.; JORGE, L. A. de C.; JUNIOR, L.; ALBUQUERQUE, R. W.; BRANCALION, P. H. S.; WILKISON, B.; COSTA, M. O. *Aboveground biomass estimation in Amazonian tropical forests: A comparison of aircraft- and gatereye UAV-borne LIDAR data in the Chico mendes extractive reserve in Acre, Brazil*. Remote Sensing, v. 12, n. 11, p. 1754, 2020.
- DEUTSCHER, Janik et al. *Mapping tropical rainforest canopy disturbances in 3D by COSMO-SkyMed spotlight InSAR-stereo data to detect areas of forest degradation*. Remote sensing, v. 5, n. 2, p. 648-663, 2013.
- DOS SANTOS, L. T. et al. *Multitemporal segmentation of sentinel-2 images in an agricultural intensification region in brazil*. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 3, p. 389-395, 2022.
- EUROPEAN SPACE AGENCY. *Sentinel-2: Visão geral*. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. Acesso em: 28 out. 2023.

- FERRARI, Felipe *et al.* *Fusing Sentinel-1 and Sentinel-2 Images for Deforestation Detection in the Brazilian Amazon Under Diverse Cloud Conditions*. IEEE Geoscience and Remote Sensing Letters, v. 20, p. 1-5, 2023.
- FLORES-ANDERSON, A. I.; HERNDON, K. E.; THAPA R. B.;CHERRINGTON, E. *The Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. NASA. SERVIR Global Science Coordination Office, p. 307, 2019. <https://doi.org/10.25966/nr2cs697>.
- GANDA, Larisse; SILVA, Zenobio. *Aspectos econômicos da exploração florestal nos trópicos: um estudo de caso da atividade de arraste em uma floresta manejada no estado do Amazonas, 2017*. Scientia Naturalis, v. 1, n. 5, 2019.
- GHORBANIAN, Arsalan *et al.* *Mangrove ecosystem mapping using Sentinel-1 and Sentinel-2 satellite images and random forest algorithm in Google Earth Engine*. Remote Sensing, v. 13, n. 13, p. 2565, 2021.
- GOOGLE EARTH ENGINE (1). *Sentinel-1 Guide*. Disponível em: <<https://developers.google.com/earth-engine/guides/sentinel1>>. Acesso em: 17 nov. 2023a.
- Google Earth Engine (2). *Catálogo de Dados do Sentinel-2*. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/sentinel-2>. Acesso em: 29 Agosto 2023b.
- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE R. *Google Earth Engine: Planetary-scale geospatial analysis for everyone*. Remote Sensing of Environment, v. 202, p. 18-27, 2017.
- GREGORY, Matthew J. *et al.* *Cloud-based computation for accelerating vegetation mapping and change detection at regional to national scales*. In: Stanton, Sharon M.; Christensen, Glenn A., comps. 2015. Pushing boundaries: new directions in inventory techniques and applications: Forest Inventory and Analysis (FIA) symposium 2015. 2015 December 8–10; Portland, Oregon. Gen. Tech. Rep. PNW-GTR-931. Portland, OR: US Department of Agriculture, Forest Service, Pacific Northwest Research Station. p. 178. 2015.
- HÄGGI, C. CHIESSI, C. M.;MERKEL, U.; MULITZA, S.; PRANGE, M.; SCHULZ, M.; SCHEFUß, E. *Response of the Amazon rainforest to late Pleistocene climate variability*. Earth and Planetary Science Letters, v. 479, p. 50-59, 2017.

- HANSEN, M. C., POTAPOV, P. V., MOORE, R., HANCHER, M., TURUBANOVA, S. A., TYUKAVINA, A. et al. (2013). *High-Resolution Global Maps of 21st-Century Forest Cover Change*. Science, 342(6160), 850–853. doi:10.1126/science.1244693
- HIRSCHMUGL, Manuela et al. *Use of SAR and optical time series for tropical forest disturbance mapping*. Remote Sensing, v. 12, n. 4, p. 727, 2020.
- HUYLENBROECK, L.; LASLIER, M.; DUFOUR, S.; GEORGES, B.; LEJEUNE, P.; MICHEZ, A. *Using remote sensing to characterize riparian vegetation: a review of available tools and perspectives for managers*. Journal of Environmental Management, v. 267, 2020. Art. 110652.
- Inácio, I. de A. *Detecção de áreas com exploração madeireira usando imagens de satélite Sentinel-2A no sudoeste amazônico*. Orientadora: Profa. Dra. Simone Maria de Melo Figueiredo. Universidade Federal do Acre. 2021.
- JESUS, Janisson Batista de; KUPLICH, Tatiana Mora. *Utilização de imagens SAR na classificação de formações florestais brasileiras*. Ciência Florestal, v. 31, p. 1547-1568, 2021.
- KINNEBREW, Eva et al. *Biases and limitations of Global Forest Change and author-generated land cover maps in detecting deforestation in the Amazon*. Plos one, v. 17, n. 7, p. e0268970, 2022.
- KOO, Younghyun et al. *Automated detection and tracking of medium-large icebergs from Sentinel-1 imagery using Google Earth Engine*. Remote Sensing of Environment, v. 296, p. 113731, 2023.
- KUCHLER, P. C.; SIMÕES, M.; BEGUÉ, A.; PEÇANHA, R.; ARVOR, D. *Sensoriamento remoto e análise espacial: uma contribuição para o mapeamento dos sistemas integrados de produção agropecuária*. Embrapa Solos-Capítulo em livro científico (ALICE), 2019.
- KUCK, T. N.; SANO E. E.; BISPO, P. C.; SHIGUEMORI, E. H.; FILHO, P. F. F. S.; MATRICARDI A. T. *A Comparative Assessment of Machine-Learning Techniques for Forest Degradation Caused by Selective Logging in an Amazon Region Using Multitemporal X-Band SAR Images*. Remote Sensing, v. 13, n. 17, p. 3341, 2021. <https://doi.org/10.3390/rs13173341>

- LEE, Jong-Sen *et al.* *Speckle filtering and coherence estimation of polarimetric SAR interferometry data for forest applications*. IEEE Transactions on Geoscience and Remote Sensing, v. 41, n. 10, p. 2254-2263, 2003.
- LEI, Yang *et al.* *Quantification of selective logging in tropical forest with spaceborne SAR interferometry*. Remote sensing of environment, v. 211, p. 167-183, 2018.
- LIU, Qihang *et al.* *Fusing Landsat-8, Sentinel-1, and Sentinel-2 Data for River Water Mapping Using Multidimensional Weighted Fusion Method*. IEEE Transactions on Geoscience and Remote Sensing, v. 60, p. 1-12, 2022.
- LU, Dengsheng *et al.* *A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems*. International Journal of Digital Earth, v. 9, n. 1, p. 63-105, 2016.
- LUO, Xin; TONG, Xiaohua; PAN, Haiyan. *Integrating multiresolution and multitemporal Sentinel-2 imagery for land-cover mapping in the Xiongan New Area, China*. IEEE Transactions on Geoscience and Remote Sensing, v. 59, n. 2, p. 1029-1040, 2020.
- MATARIRA, Dadirai *et al.* *Object-Based Informal Settlement Mapping in Google Earth Engine Using the Integration of Sentinel-1, Sentinel-2, and PlanetScope Satellite Data*. Land, v. 12, n. 1, p. 99, 2022.
- MATHIEU, R.; NAIDOO, L.; CHO, M. A.; LEBLON, B.; MAIN, R.; WESSELS, K.; ASNER, G. P.; BUCKLEY, J.; AARDT, J. V.; ERASMUS, B. F. N.; SMIT, I. P. J. *Toward structural assessment of semi-arid African sa's'vannahs and woodlands: the potential of multitemporal polarimetric RADARSAT-2 fine beam images*. Remote Sens. Environ. 138 (November), 215–231. 2013. <https://doi.org/10.1016/j.rse.2013.07.011>.
- MAUYA, Ernest William; MADUNDO, S. *Modelling Above Ground Biomass Using Sentinel 2 and Planet Scope Data in Dense Tropical Montane Forests of Tanzania*. Tanzania Journal of Forestry and Nature Conservation, v. 91, n. 1, p. 132-153, 2022.
- MENESES, Paulo Roberto; ALMEIDA, T. de. *Introdução ao processamento de imagens de sensoriamento remoto*. Universidade de Brasília, Brasília, 2012.
- MENEZES, S. J. M. C.; RIBEIRO, C. A. A. S.; LIMA, C. A.; SOUZA, M. O. A. *Geotecnologias aplicadas à gestão ambiental*. Revista Diversidade e Gestão, Rio de Janeiro, v. 1, n. 1, p. 57-69. 2017. Volume especial. Gestão ambiental: perspectivas, conceitos e casos.

- MENG, Shili *et al.* *A Multifactor Weighting Method for Improved Clear View Compositing Using All Available Landsat 8 and Sentinel 2 Images in Google Earth Engine*. Journal of Remote Sensing, v. 3, p. 0086, 2023.
- MOHARRAMI, Meysam; JAVANBAKHT, Mohammad; ATTARCHI, Sara. *Automatic flood detection using sentinel-1 images on the google earth engine*. Environmental monitoring and assessment, v. 193, p. 1-17, 2021.
- MUTANGA, O.; KUMAR, L. *Google earth engine applications*. Remote Sensing, v. 11, n. 5, p. 591, 2019.
- NANNI, A. S.; SLOAN, S. AIDE, T. M.; GRAESSER, J.; EDWARDS, D.; GRAU, H. R. *The neotropical reforestation hotspots: A biophysical and socioeconomic typology of contemporary forest expansion*. Global Environmental Change, v. 54, p. 148-159, 2019.
- NANNI, A. S.; SLOAN, S. AIDE, T. M.; GRAESSER, J.; EDWARDS, D.; GRAU, H. R. *The neotropical reforestation hotspots: A biophysical and socioeconomic typology of contemporary forest expansion*. Global Environmental Change, v. 54, p. 148-159, 2019.
- NEGRI, R. G.; DUTRA, L. V.; COSTA, C. C.; LU, D. *Exploring the capability of ALOS PALSAR L-band fully polarimetric data for land cover classification in tropical environments*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 9, n. 12, p. 5369-5384, 2016.
- NICOLAU, A. P.; FLORES-ANDERSSON, A.; GRIFFIN, R.; HERNDON, K.; MEYER, F. J. *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, v. 94, p. 102214, 2021.
- PERBET, Pauline *et al.* *Near real-time deforestation detection in Malaysia and Indonesia using change vector analysis with three sensors*. International Journal of Remote Sensing, v. 40, n. 19, p. 7439-7458, 2019.
- PLANET TEAM. *Planet Application Program Interface: In Space for Life on Earth*. San Francisco, CA, 2017. Disponível em: <https://api.planet.com>. Acesso em: 29 ago. 2023.
- PLANO OPERACIONAL ANUAL (POA). *Plano operacional anual - Fazenda Seringal Novo Macapá*. Rio Branco: Agrocortex Madeiras do Acre Agroflorestal Ltda, 2017

- PODEST, E.; MCCULLUM, A.; TORRES-PÉREZ, J.; MCCARTNEY, S.; SIQUEIRA, P.; LEI, Y.; WHELEN, T.; KRAATZ, S. *Mapeo y Monitoreo de los Bosques con Datos SAR*. NASA Applied Remote Sensing Training Program (ARSET). (2020). <https://appliedsciences.nasa.gov/join-mission/training/spanish/arset-mapeo-y-monitoreo-de-los-bosques-con-datos-sar>
- RAO, Preeti *et al.* *Using Sentinel-1, Sentinel-2, and Planet imagery to map crop type of smallholder farms*. Remote Sensing, v. 13, n. 10, p. 1870, 2021.
- REHMAN, Touseef Ur *et al.* *Long short term memory deep net performance on fused Planet-Scope and Sentinel-2 imagery for detection of agricultural crop*. Plos one, v. 18, n. 2, p. e0271897, 2023.
- RODRIGUES, Maisa Isabela *et al.* *Concessão florestal na Amazônia brasileira*. Ciência Florestal, v. 30, p. 1299-1308, 2020.
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. *Monitoring vegetation systems in the great plains with ERTS*. In: ERTS SYMPOSIUM, 3., 1973, Washington. Proceedings. Washington: NASA, p.309-317, 1973
- RYAN, Casey M. *et al.* *Quantifying small-scale deforestation and forest degradation in African woodlands using radar imagery*. Global Change Biology, v. 18, n. 1, p. 243-257, 2012.
- RYAN, Casey M.; BERRY, Nicholas J.; JOSHI, Neha. *Quantifying the causes of deforestation and degradation and creating transparent REDD+ baselines: A method and case study from central Mozambique*. Applied Geography, v. 53, p. 45-54, 2014.
- SANTOS, J. R.; LINGNAU, C.; LOPES, E. S. *Do laser terrestre ao uso de imagens radar: pesquisas e aplicações na área florestal*. AMBIÊNCIA, v. 8, n. 4, p. 439-442, 2012.
- SANTOS, João Roberto *et al.* *Mapping recent deforestation in the Brazilian Amazon using simulated L-band MAPSAR images*. International Journal of Remote Sensing, v. 29, n. 16, p. 4879-4884, 2008.
- SARZYNSKI, Thuan *et al.* *Combining radar and optical imagery to map oil palm plantations in Sumatra, Indonesia, using the Google Earth Engine*. Remote Sensing, v. 12, n. 7, p. 1220, 2020.

- SHIMADA, M., ITOH, T., MOTOOKA, T., WATANABE, M., SHIRAISHI, T., THAPA, R., LUCAS, R. 2014. *New global forest/non-forest maps from ALOS PALSAR data (2007–2010)*. Remote Sens. Environ. 155, 13–31.
- SILVA, ANGELA GABRIELLY PIRES et al. *Integração de imagens Orbitais Ópticas e SAR Com Processamento em Nuvem no Mapeamento da Cobertura da Terra no Cerrado*. Revista Geoaraguaia, v. 11, n. Especial, p. 85-106, 2021.
- SILVA, Claudia Arantes et al. *Análise qualitativa do desmatamento na Floresta Amazônica a partir de sensores SAR, óptico e termal*. Anuário do Instituto de Geociências, v. 42, n. 4, p. 18-29, 2019. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/31314>. Acesso em: 02 ago. 2022.
- SLAGTER, Bart et al. *Monitoring direct drivers of small-scale tropical forest disturbance in near real-time with Sentinel-1 and-2 data*. Remote Sensing of Environment, v. 295, p. 113655, 2023.
- Smith, J. R., & Johnson, A. B. *Impact of Defoliation on Satellite Image Interpretation in Tropical Rainforests*. Remote Sensing Letters, 25(3), 456-468. 2020.
- Sugimoto, R.; Kato, K.; Nakamura, R.; Tsutsumi, C.; Yamaguchi, Y. *Deforestation detection using scattering power decomposition and optimal averaging of volume scattering power in tropical rainforest regions*. Remote Sensing of Environment, v. 275, p. 113018, 2022.
- TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M. QUACKENBUSH, L.; ADELI, S.; BRISCO, B. *Google Earth Engine for geo-big data applications: A meta-analysis and systematic review*. ISPRS Journal of Photogrammetry and Remote Sensing, v. 164, p. 152-170, 2020.
- Tanase, M. A.; Villard, I.; Pitar, D.; Apostol, B.; Petrila, M.; Chivulescu, S.; Leca, S.; Borlafmena, I.; Pascu, I. S.; Dobre, A. C.; Pitar, D.; Guiman, G.; Lorent, A.; Anghelus, C.; Ciceu, A.; Nedea, G.; Stanculeanu, R.; Popescu, F.; Aponte, C.; Badea, O. *Synthetic aperture radar sensitivity to forest changes: A simulations-based study for the Romanian forests*. Science of the Total Environment, v. 689, p. 1104–1114, 2019.
- TAVUS, Beste; KOCAMAN, Sultan; GOKCEOGLU, Candan. *Flood damage assessment with Sentinel-1 and Sentinel-2 data after Sardoba dam break with GLCM features and Random Forest method*. Science of The Total Environment, v. 816, p. 151585, 2022.

- VALERIANO, M. M.; MOREIRA, P. E.; SANCHES, I. D. A.; FORMAGGIO, A. R. *Efeito topográfico sobre índices de vegetação obtidos com dados Landsat TM: é necessário correção topográfica?*. Boletim de Ciências Geodésicas, v. 22, n. 1, p. 95-107, 2016.
- VENTURINO, R.; SCHALL, U. M.; SOLICHIN, U. J. *Google Earth Engine As a Remote Sensing Tool*. International Journal of Remote Sensing & Geoscience, p. 1–15, 2014.
- WATANABE, Manabu et al. *Refined algorithm for forest early warning system with ALOS-2/PALSAR-2 ScanSAR data in tropical forest regions*. Remote Sensing of Environment, v. 265, p. 112643, 2021.
- WATZLAWICK, L.F.; KIRCHNER, F.F.; SANQUETTA, C.R. *Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite IKONOS II*. Ciência Florestal, v.19, p.169-181, 2009.
- ZHANG, Tao et al. *Rice and Greenhouse Identification in Plateau Areas Incorporating Sentinel-1/2 Optical and Radar Remote Sensing Data from Google Earth Engine*. Remote Sensing, v. 14, n. 22, p. 5727, 2022a.

APÊNDICES

Nome da revista: Revista de Geociências do Nordeste – REGNE

ISSN Online: 2447-3359

Editora: Universidade Federal do Rio Grande do Norte – UFRN

Fator de Impacto (2017): 0,8

Classificação Qualis/Capes em Ciências Agrárias: A1.

Link para acesso às normas da revista (instruções para autores):

<https://periodicos.ufrn.br/revistadoregne/index>

Anexos

Links de acesso:

<https://code.earthengine.google.com/5c07bc1e7eb744224706a3a4e0b14d35>

<https://code.earthengine.google.com/fda0b07ecd3b749872fd8de056569b01>

➤ SCRIPT:

```
var UPA14 = ee.FeatureCollection("users/script_Queimadas/UPA_14");

// Load Sentinel-1 C-band SAR Ground Range collection (log scale, VV, descending)
var collectionVV = ee.ImageCollection('COPERNICUS/S1_GRD')
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .filterBounds(roi2)
  .map(function(image) {
    return image.clip(roi2);
  })
  .select('VV');
print(collectionVV, 'S1_Collection VV');

// Load Sentinel-1 C-band SAR Ground Range collection (log scale, VH, descending)
var collectionVH = ee.ImageCollection('COPERNICUS/S1_GRD')
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .filterBounds(roi2)
  .map(function(image) {
    return image.clip(roi2);
  })
  .select('VH');
print(collectionVH, 'S1_Collection VH');

// Filter by date
var second2019VV = collectionVV.filterDate('2019-09-01', '2019-10-31').mosaic();
var third2020VV = collectionVV.filterDate('2020-09-01', '2020-10-31').mosaic();
var second2019VH = collectionVH.filterDate('2019-09-01', '2019-10-31').mosaic();
var third2020VH = collectionVH.filterDate('2020-09-01', '2020-10-31').mosaic();
var image1 = ee.Image(second2019VV).first();
var image2 = ee.Image(third2020VV).first();

// 2019 VV Histogram Chart
var histogramChart19 = ui.Chart.image.histogram({
  image: second2019VV,
  region: roi2,
  scale: 300
}).setOptions({
  title: 'SAR VV 2019',
  hAxis: {
    title: 'Valor do Pixel',
    minValue: -5,
    maxValue: -10,
    gridlines: {
      count: 10
    }
  },
  vAxis: {
```

```

    title: 'Contagem',
    minValue: 0,
    maxValue: 20,
    gridlines: {
      count: 10
    }
  },
  colors: ['green'],
});
print(histogramChart19);

// 2020 VV Histogram Chart
var histogramChart202 = ui.Chart.image.histogram({
  image: third2020VV,
  region: roi2,
  scale: 300
}).setOptions({
  title: 'SAR VV 2020',
  hAxis: {
    title: 'Valor do Pixel',
    minValue: -5,
    maxValue: -9,
    gridlines: {
      count: 10
    }
  },
  vAxis: {
    title: 'Contagem',
    minValue: 0,
    maxValue: 15,
    gridlines: {
      count: 10
    }
  },
  colors: ['green'],
});
print(histogramChart202);

// -----PLANET - 2019 -----
var nicfi = ee.ImageCollection('projects/planet-nicfi/assets/basemaps/americas')
  .map(function(image){return image.clip(roi2)})
  .filterBounds(roi2);
print (nicfi, "nicfi_2019");
// Filter basemaps by date and get the first image from filtered results
var basemap1= nicfi.filter(ee.Filter.date('2019-09-01','2019-11-30')).reduce(ee.Reducer.first());
var vis1 = {"bands":["R","G","B"],"min":64,"max":5454,"gamma":1.8};
var visualized1 = basemap1.visualize(vis1);
Map.addLayer(visualized1, {}, 'Planet_2019-09');
var visAA = basemap1.normalizedDifference(['N','R']).rename('Planet_NDVI_19').clip(UPA14);
Map.addLayer(visAA, {}, 'Planet_NDVI_19A');
var chart = ui.Chart.image.histogram({image: visAA, region: UPA14, scale: 10})
  .setSeriesNames(['NDVI'])
  .setOptions({
    title: 'NDVI Planet 2019',
    hAxis: {
      title: 'NDVI value',
      titleTextStyle: {italic: false, bold: true},
      minValue: 0.7,
      maxValue: 0.97
    },
    vAxis: {
      title: 'Count',
      titleTextStyle: {italic: false, bold: true}},
    colors: ['green']
  });
print(chart);
var crs = visualized1.projection();

```

```

print("CRS da imagem:", crs);
Export.image.toDrive({
  image: visualized1,
  description: 'Planet_2019',
  region: UPA14,
  scale: 4.777314267159966,
  crs: 'EPSG:4326',
  folder: "DISSERTACAO_PLANET",
});
// -----
var basemap5 = nicfi.filter(ee.Filter.date('2019-09-01', '2019-11-30')).reduce(ee.Reducer.first());
var vis5 = {"bands": ["R", "G", "B"], "min": 147, "max": 413, "gamma": 1.8};
var imagea5 = basemap5.visualize(vis5);
Map.addLayer(basemap5, vis5, 'Planet_2019-09');
// print(histogramChart10);
var histogramChart10 = ui.Chart.image.histogram({
  image: imagea5,
  region: roi2
}).setOptions({
  title: 'planet_2019',
  hAxis: {
    title: 'Valor do Pixel'
  },
  vAxis: {
    title: 'Contagem',
    format: '#', // Define o formato como números inteiros
  },
  colors: ['green']
});
print(histogramChart10);
Export.image.toDrive({
  image: imagea5,
  description: 'Planet_2019_RGB2',
  region: UPA14,
  scale: 4.777314267159966,
  // crs: 'EPSG:4326',
  folder: "DISSERTACAO_PLANET",
});
Export.image.toDrive({
  image: imagea5,
  description: 'Planet_2019_RGB3',
  region: UPA14,
  scale: 4.777314267159966,
  // crs: 'EPSG:4326',
  folder: "DISSERTACAO_PLANET",
});

// ----- PLANET - 2019 -----
var nicfi = ee.ImageCollection('projects/planet-nicfi/assets/basemaps/americas')
  .map(function(image){return image.clip(roi2)})
  .filterBounds(roi2);

var basemap1= nicfi.filter(ee.Filter.date('2019-09-01','2019-11-30')).reduce(ee.Reducer.first());
var vis1 = {"bands":["R","G","B"],"min":64,"max":5454,"gamma":1.8};
var visualized1 = basemap1.visualize(vis1);
Map.addLayer(visualized1, {}, 'Planet_2019-09');

var visAA = basemap1.normalizedDifference(['N','R']).rename('Planet_NDVI_19').clip(UPA14);
Map.addLayer(visAA, {}, 'Planet_NDVI_19A');

// ... (restante do código)

// ----- SENTINEL-2 -----
var sent2_2020_col = ee.ImageCollection("COPERNICUS/S2_HARMONIZED")
  .filter(ee.Filter.lte('CLOUDY_PIXEL_PERCENTAGE', 01))
  .map(function(image){return image.clip(UPA14)})
  .filterDate('2020-10-10', '2020-11-30')

```

```

.filterBounds(UPA14);

var Mean_2020 = sent2_2020_col.reduce(ee.Reducer.min());
Map.addLayer(Mean_2020, {min:664, max:1267}, 'S2_Mean_2020');

// ... (restante do código)

// ----- SENTINEL-1 - 2019 -----
var col_2019 = ee.ImageCollection("COPERNICUS/S1_GRD")
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .map(function(image){return image.clip(UPA14)})
  .filterDate('2019-05-01', '2019-11-01')
  .filter(ee.Filter.calendarRange(8,11, 'month'))
  .filterBounds(UPA14);

var Mean_2019 = col_2019.reduce(ee.Reducer.mean());
Map.addLayer(Mean_2019, {min:-20, max:10}, 'Mean_2019');

// ... (restante do código)

// ----- SENTINEL-1 - 2020 -----
var col_2020= ee.ImageCollection("COPERNICUS/S1_GRD")
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .map(function(image){return image.clip(UPA14)})
  .filterDate('2020-05-01', '2020-12-01')
  .filter(ee.Filter.calendarRange(8,12, 'month'))
  .filterBounds(UPA14);

var Mean_2020 = col_2020.reduce(ee.Reducer.mean());
Map.addLayer(Mean_2020, {min:-20, max:10}, 'Mean_2020');

// Compute band difference for Sentinel-1 SAR;
var diffS1 = (compositeS12020.subtract(compositeS12019)).abs();
Map.addLayer(diffS1, {}, 'composite2020SAR-2019SAR', false);
var chart2 = ui.Chart.image.histogram({image: diffS1, region: UPA14, scale:100})
  .setSeriesNames(['VALORES VV/VH'])
  .setOptions({
    title: 'Composição SAR 2019-2020',
    hAxis: {
      title: 'NDVI value',
      titleTextStyle: {italic: false, bold: true},
      minValue: -300,
      maxValue: 300
    },
    vAxis: {
      title: 'Contagem', titleTextStyle: {italic: false, bold: true}},
    colors: [],
  });
print(chart2);

var histogramChart2 = ui.Chart.image.histogram({
  image: diffS1,
  region: roi,
  scale: 300
}).setOptions({
  title: 'S1_dif 2019/2020',
  hAxis: {
    title: 'Valor do Pixel VV/VH',

```

```

    },
    vAxis: {
      title: 'Contagem',
    },
    colors: [], // Defina a cor verde aqui
  });
print(histogramChart2);
// Defina o critério para criar a máscara (por exemplo, diferença maior que um valor)
var threshold = 0.5;
var mask = diffS1.gte(threshold); // Cria uma máscara de true/false
// Aplica a máscara à imagem diffS1
var maskedDiffS1 = diffS1.updateMask(mask);
// Adiciona a camada com a imagem mascarada
Map.addLayer(maskedDiffS1, {min: 0, max: 1, palette: ['white', 'blue']}, 'DiffS1 Mascarada');
// Adiciona a camada original (não mascarada) para comparação
Map.addLayer(diffS1, {}, 'composite2020SAR-2019SAR Original', false);
print('Projection, crs, and crs_transform:', basemap.projection());
print('Scale in meters:', basemap.projection().nominalScale());
Export.image.toDrive({
  image: diffS1,
  description: 'diffS1',
  region: UPA14,
  scale: 10,
  crs: 'EPSG:4326',
  folder: "AREA DE ESTUDO",
});
// Get filtered data from collection - 2020-07-01 - 2020-07-01
var img_db= ee.Image(ee.ImageCollection("COPERNICUS/S1_GRD_FLOAT")
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .map(function(image){return image.clip(UPA14)}))
  .filterDate('2020-05-01', '2020-11-01') // Three years of data
  .filter(ee.Filter.calendarRange(7,11, 'month')) // Only Nov-Feb observations
  .filterBounds(UPA14));
// .first(); // Intersecting ROI
var new_img = ee.Image.rgb( img_db.select('VV'),
                           img_db.select('VH'),
                           img_db.select('VV').divide(img_db.select('VH')));
Map.addLayer ((new_img), {}, 'RGB_2020',1);

// Map.addLayer(new_img, {min:[-20,-20,-20] , max:[2,2,2] }, 'rgb_co');
// Get filtered data from collection - 2020-07-01 - 2020-07-01
var img_col=ee.ImageCollection("COPERNICUS/S1_GRD_FLOAT")
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
  .filter(ee.Filter.eq('instrumentMode', 'TW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  .filterMetadata('resolution_meters', 'equals', 10)
  .map(function(image){return image.clip(UPA14)}))
  .select('VV')
  .filterDate('2020-05-01', '2020-12-01') // Three years of data
  .filter(ee.Filter.calendarRange(8,12, 'month')) // Only Nov-Feb observations
  .sort('system:time_start')
  .filterBounds(UPA14); // Intersecting ROI
//.first()
print(img_col);
var acq_times = img_col.aggregate_array('system:time_start').getInfo()
var im_list = img_col.toList(img_col.size())
var im1 = ee.Image(im_list.get(0)).select('VV')
var im2 = ee.Image(im_list.get(1)).select('VV')
var ratio = im1.divide(im2)
print(ratio, 'ratio');
var new_img = ee.Image.rgb( img_db.select('VV'),
                           img_db.select('VH'),

```

```

        img_db.select('VV').divide(img_db.select('VH')));
    Map.addLayer(new_img,{}, 'RGBSENTINEL');
    var img_col_19=ee.ImageCollection("COPERNICUS/S1_GRD_FLOAT")
    .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
    .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
    .filter(ee.Filter.eq('instrumentMode', 'TW'))
    .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
    .filterMetadata('resolution_meters', 'equals', 10)
    .map(function(image){return image.clip(UPA14)})
    .select('VH')
    .filterDate('2019-05-01', '2019-12-01') // Three years of data
    .filter(ee.Filter.calendarRange(9,11, 'month')) // Only Nov-Feb observations
    .sort('system:time_start')
    .filterBounds(UPA14); // Intersecting ROI
    //first()
    var im_list_19= img_col_19.toList(img_col_19.size())
    // var im3 = ee.Image(im_list_19.get(0)).select('VV')
    // Map.addLayer(im1.log10().multiply(10), {'min': -20,'max': 20}, 'ratio');
    // Map.addLayer(im2.log10().multiply(10), {'min': -20,'max': 20}, 'ratio2');
    // Map.addLayer(im1.log10().multiply(10).addBands(im3.log10().multiply(10)), {'min': -20,'max': 0}, 'ratio3');
    // Get filtered data from collection - 2020-07-01 - 2020-07-01
    var col_2020= ee.ImageCollection("COPERNICUS/S1_GRD")
    .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
    .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
    .filter(ee.Filter.eq('instrumentMode', 'TW'))
    .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
    .filterMetadata('resolution_meters', 'equals', 10)
    .map(function(image){return image.clip(UPA14)})
    .filterDate('2020-05-01', '2020-12-01') // Three years of data
    .filter(ee.Filter.calendarRange(8,9, 'month')) // Only Nov-Feb observations
    .filterBounds(UPA14); // Intersecting ROI
    print(col_2020, 'col_2020')
    Map.addLayer(col_2020, {min:-20 ,max:0 }, 'col_2020', 0);

    var Mean_2020 = col_2020.reduce(ee.Reducer.mean())
    print(Mean_2020, 'Mean_2020')
    Map.addLayer(Mean_2020, {}, 'Mean_2020', 0);
    var Mean2019_2020 = ((Mean_2019.subtract(Mean_2020)).lt(1),{},'Mean2019_2020');
    print(Mean2019_2020, 'Mean2019_2020');
    var new_img2 = image.normalizedDifference.Mean2019_2020;
    Map.addLayer(Mean_2019.subtract(Mean_2020).lt(1.2),{},'2019/2020 Mean1.2');
    Map.addLayer(Mean_2019.subtract(Mean_2020).lt(1),{},'2019/2020 Mean1');
    Map.addLayer(Mean_2019.subtract(Mean_2020).lt(0.8),{},'2019/2020 Mean8');
    var image = ee.Image(Mean_2019.subtract(Mean_2020).lt(1.3)).select([0,1,2], ['b20192020Mean']);
    var binaryMask = image.eq(1);
    Map.addLayer(image, {}, 'b2019220Mean');
    var maskedImage = image.updateMask(binaryMask);

    Map.addLayer(maskedImage, {}, 'Mean20192020Masked');

    Export.image.toDrive({
    image: maskedImage,
    description: 'Mean20192020Masked',
    region: UPA14,
    scale: 10,
    folder: "AREA DE ESTUDO3",
    });
    Export.image.toDrive({
    image: image,
    description: 'b20192020Mean',
    region: UPA14,
    scale: 10,
    // crs: 'EPSG 4674',
    folder: "AREA DE ESTUDO3",

```