

INTEGRAÇÃO ENTRE SENTINEL-1 E SENTINEL-2 PARA CLASSIFICAÇÃO DA IDADE DE PLANTIOS COMERCIAIS DE *EUCALYPTUS* SP.

Juliana Maria Ferreira de Souza Diniz¹, Sabrina Paes Leme Passos Correa¹, Jeanderlon Veiga¹, Ivy Mayara Sanches de Oliveira¹, Emerson Roberto Schoeninger¹

¹Bracell, Lençóis Paulista, São Paulo, Brasil,- 18685-907, jdiniz@bracell.com; scorrea@bracell.com, jveiga@bracell.com, isanches@bracell.com, eschoeninger@bracell.com

RESUMO

O crescimento das indústrias de papel e celulose aumenta constantemente a demanda por madeira, o que faz o mapeamento por novos povoamentos florestais indispensável. Uma das formas de realizar este mapeamento é através de imagens de sensoriamento remoto. Além disso, a integração entre sensores ativos e passivos permite um melhor entendimento sobre as características da floresta. Dentre as variáveis importantes para direcionar a compra de madeira, há a idade dos plantios, que está relacionada à produtividade florestal. Assim, o objetivo deste trabalho foi avaliar a integração entre os dados do sensor ativo SAR do Sentinel-1 e o sensor passivo MSI do Sentinel-2 para mapeamento da idade de plantios de *Eucalyptus* sp.. Nesse caso, foram definidos três experimentos, variando os intervalos de idade e 4 cenários de classificação, que avaliaram as variáveis provenientes dos sensores. Foi observado que o experimento A e o cenário 4 foram os que apresentaram os melhores desempenhos.

Palavras-chave — SAR, aprendizagem de máquina, classificação de imagens, random forest.

ABSTRACT

The growth of paper and cellulose industries constantly increases the demand for wood, resulting in an indispensable mapping of new forests and remote sensing is one of the approaches for mapping them. Besides, integration between active and passive sensors allows a better understanding about the forest characteristics. An important factor for decision making related to buying wood is the planting age, which is related to forest productivity. Thus, this study aimed to assess the integration between data from the active sensor SAR from Sentinel-1 and the passive sensor MSI from Sentinel-2 to map Eucalyptus sp. age. In this case, there were three experiments varying age's interval and four classification scenarios, which evaluated the variables of both sensors. We observed that the experiment A and scenario 4 presented the best performance.

Key words — SAR, machine learning, image classification, random forest.

1. INTRODUÇÃO

O setor de silvicultura voltado para florestas plantadas tem crescido exponencialmente no Brasil, onde movimentou R\$18,8 bilhões em 2020 [1]. Desse modo, para garantir o abastecimento da cadeia produtiva, os setores de base florestal, como a indústria de papel e celulose, estão investindo em geotecnologias e aplicações de sensoriamento remoto para encontrar fornecedores de madeira, principalmente em uma cadeia produtiva que vem crescendo cada vez mais e a necessidade da busca de novas áreas para matéria-prima se torna indispensável.

Desse modo, a utilização do sensoriamento remoto para mapeamento de novas áreas tem sido cada vez mais frequente. Além de permitirem a localização dos plantios florestais, as técnicas de sensorimento remoto por meio de dados orbitais possibilitam também a extração de outras variáveis importantes da floresta, a exemplo da idade de plantio. A idade é uma variável que, além de ser essencial para o inventário florestal, pode direcionar para áreas mais viáveis, de acordo com o plano estratégico de suprimento de madeira.

Geralmente, as informações de idade fazem parte da base de dados da empresa. No entanto, quando se pretende prospectar novas áreas florestais, essa informação pode não estar disponível. Nesse caso, é necessário uma metodologia que possibilite a identificação da idade de plantios, fornecendo subsídios para as tomadas de decisão.

Nesse contexto, o sensoriamento remoto surge como uma forma de monitorar e mapear grandes áreas, que podem identificar novos povoamentos florestais. Aliado a isso, imagens geradas a partir dos sensores SAR (*Synthetic Aperture Radar*) permitem maiores informações sobre a estrutura da floresta, além de gerar dados menos influenciados pelas condições atmosféricas [2].

Desse modo, o objetivo deste trabalho foi avaliar o potencial dos dados SAR do Sentinel-1 e a sua integração com dados ópticos do Sentinel-2 para classificação da idade de talhões de *Eucalyptus* sp. no interior do Estado de São Paulo.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo compreende talhões de *Eucalyptus* sp. da empresa Bracell, localizados no interior de São Paulo (Fig. 1). A Bracell é uma das líderes na produção de celulose solúvel, incluindo celulose especial solúvel. A produção é realizada com recurso natural e 100% renovável, com eucalipto produzido de forma sustentável. Para esse trabalho, foram utilizados 1275 talhões, com idades variando entre 1 a 15 anos.



Fig. 1 Localização geográfica da área de estudo.

2.2 Dados Sentinel-1 e Sentinel-2

Para esse trabalho foram utilizados dados do sensor C-SAR acoplado ao satélite Sentinel-1, disponibilizados gratuitamente pela Agência Espacial Européia (ESA) [3]. Os dados foram adquiridos no formato SLC (*Single Look Complex*), que contém as informações de fase e quadratura.

Características	Sentinel-1	Sentinel-2
Datas	26/09/2022 e 08/10/2022	27/08/2022 e 01/09/2022
Modo de imageamento	IW	-
Banda	C	Todas as bandas espectrais
Polarizações	VV e VH	-
Resolução Temporal		6 dias
Resolução Espacial	2,7x22 até 3,5x22 m	10, 20 e 60m

Tab. 1 Descrição dos dados utilizados do Sentinel-1 e Sentinel-2.

Foram utilizados também dados do sensor *MultiSpectral Imager* (MSI) acoplado ao satélite Sentinel-2 no nível 2A de processamento, que são dados em reflectância de superfície [4]. As informações obtidas dos satélites são encontradas na Tab. 1.

2.2 Pré-processamento

As etapas de pré-processamento do Sentinel-1 foram realizadas no software SNAP (*Sentinel Applications Platform*) [5]. A primeira etapa foi a aplicação da operação *Split*, selecionando-se a sub-faixa IW3, correspondente à área de estudo. Em seguida aplicou-se a operação *Apply Orbit File*, que atualiza as informações de órbita do satélite. Para obtenção dos coeficientes de retroespalhamento (σ^0) foi aplicada a calibração (Eq. 1). Em seguida, foi aplicada a operação *deburst* que visa unir os *bursts* presentes na imagem. O *multilook* foi aplicado com 4 *looks* em *range* e 1 *look* em *azimute*, buscando deixar a imagem mais regular. Foi aplicado o filtro Lee com uma janela 3x3 para reduzir o efeito *Speckle*. Por fim, foi realizada a correção do terreno, utilizando o modelo digital de elevação do SRTM com 30m de resolução espacial.

$$\sigma^0 = \frac{|DN|^2}{A_i^2} \quad (1)$$

Os coeficientes de retroespalhamento foram utilizados para obtenção dos seguintes índices provenientes do Sentinel-1:

- Índice de Vegetação de Radar:

$$RVI = (4 * \sigma_{VH}^0) / (\sigma_{VV}^0 + \sigma_{VH}^0) \quad (2)$$

- Razão Crosspolarizada:

$$CR = \sigma_{VH}^0 / \sigma_{VV}^0 \quad (3)$$

- Razão Normalizada:

$$NL = (\sigma_{VV}^0 * \sigma_{VH}^0) / (\sigma_{VV}^0 + \sigma_{VH}^0) \quad (3)$$

- Radar Gap Index*:

$$RGI = (\sigma_{VV}^0 - \sigma_{VH}^0) / (\sigma_{VV}^0 + \sigma_{VH}^0) \quad (4)$$

Além das variáveis provenientes dos coeficientes de retroespalhamento, foram obtidas a decomposição polarimétrica *H-a* para dados *dual* e a coerência interferométrica.

Para a coerência interferométrica foi realizado o corregristo entre as duas cenas coletadas nos dias 26/09/2022 e 08/10/2022. Após o corregristo, foram obtidas as coerências interferométricas (γ) nas polarizações VV e VH através da Eq. 5, onde S1 e S2 representam as duas imagens do Sentinel-1 complexas corregristadas e o colchete $\langle \dots \rangle$ representa a média em relação ao tamanho da janela (10x3).

$$\gamma = \frac{|\langle S_1(x)S_2(x)^* \rangle|}{\sqrt{\langle |S_1(x)|^2 \rangle \langle |S_2(x)|^2 \rangle}} \quad (5)$$

Em seguida, foram aplicadas as etapas de *deburst*, *multilooking*, filtragem e correção do terreno seguindo os mesmos parâmetros dos coeficientes de retroespalhamento.

As variáveis do Sentinel-1 e as bandas espectrais do Sentinel-2 com resolução espacial maior que 10m, foram reamostradas para 10m, com o objetivo de ficarem com o mesmo tamanho de pixel das bandas do Sentinel-2.

2.3 Classificação da idade dos plantios

Para a classificação das idades dos plantios foram definidos três experimentos, que variaram os valores de classe de idade como mostra a Tab. 2.

Classes	Experimentos		
	A	B	C
1	1 a 4	1 a 3	1 a 4
2	5 a 7	4 a 6	5 a 8
3	> 8	> 7	> 9

Tab. 2 Classes de idade (anos) para os experimentos A, B e C.

Além disso, com o objetivo de avaliar as variáveis extraídas do Sentinel-1 e a integração com as bandas espectrais do Sentinel-2, foram definidos 4 cenários de classificação (Erro! Fonte de referência não encontrada.2).

Cenários	Variáveis
Cenário 1	σ^0 + índices
Cenário 2	Decomposição + Coerência
Cenário 3	σ^0 + índices + Decomposição + Coerência
Cenário 4	Cenário 3 + Bandas do Sentinel-2

Tab. 2 Cenários de classificação com as variáveis do Sentinel-1 e Sentinel-2.

A classificação foi realizada com o classificador *Random Forest* [6], aplicado em ambiente R [7], com o número de árvores igual a 500 e o número de variáveis amostradas aleatoriamente como candidatas igual a raiz quadrada das variáveis utilizadas. As amostras foram divididas em 70% para treinamento e 30% para validação. A análise dos resultados foi realizada através da acurácia global e acurácias do produtor e usuário.

3. RESULTADOS

A Tab. 3 apresenta os resultados de Acurácia Global (%) obtidos para cada experimento e cada cenário analisado.

Nesse caso, foi possível perceber que o experimento B apresentou os melhores valores de acurácia global para todos os cenários analisados.

Já a integração com as bandas espectrais do Sentinel-2 no cenário 4 apresentou um aumento dos resultados de todos os experimentos, correspondendo a 37,44%, 33,11% e 30,11% para os experimentos A, B e C, respectivamente, em relação ao cenário 2, que obteve o pior desempenho.

Cenários	Experimentos		
	A	B	C
1	47,12	54,57	53,93
2	39,79	47,78	47,38
3	50,52	56,92	54,97
4	77,23	80,89	77,49

Tab. 3 Acurácia Global (%) para cada experimento e cenário analisado.

A Fig. 2 apresenta os valores de acurácia do produtor e usuário para os experimentos e cenários analisados. De modo geral, nota-se que os dados do Sentinel-1 apresentaram uma maior facilidade para a classificação de idades mais novas (Classe 1), com maiores valores de acurácias para todos os cenários e experimentos.

Nota-se ainda, que apesar do experimento B ter apresentado o maior valor de acurácia global, o experimento A apresentou bons resultados de acurácias do produtor e usuário para todas as classes analisadas.

A classe 3, que representa os plantios com idades mais avançadas, variou entre idades maiores que 8, 7 e 9 anos, para os experimentos A, B e C respectivamente. Percebe-se que essa classe apresentou os menores valores de acurácias do produtor para todos os experimentos, com os maiores erros de omissão. O comportamento da classe 3 nos experimentos B e C apresentou acurácia do usuário alta, no entanto, isso não ocorreu para a acurácia do produtor.

A integração com as bandas espectrais do Sentinel-2 (Cenário 4) representou uma melhora nos valores de acurácias do produtor e usuário para todas as classes em todos os cenários e experimentos analisados.

4. DISCUSSÃO

Os dados do Sentinel-1, individualmente, apresentaram melhor desempenho para a classe 1 em todos os experimentos analisados, o que pode estar relacionado à capacidade de penetração da banda C. Em plantios mais novos, a radiação conseguiu interagir melhor com a floresta e captar as características existentes. Já em plantios mais velhos, com a copa fechada, os dados da banda C ficam restritos às copas, não interagindo com a parte inferior da floresta, o que pode impactar na estimativa da idade. Nesse caso, a utilização de sensores SAR com maiores comprimentos de onda, poderiam melhorar o mapeamento desta classe por possibilitarem uma maior interação entre a radiação eletromagnética e o sub-bosque florestal, como é o caso das bandas L e P [8].

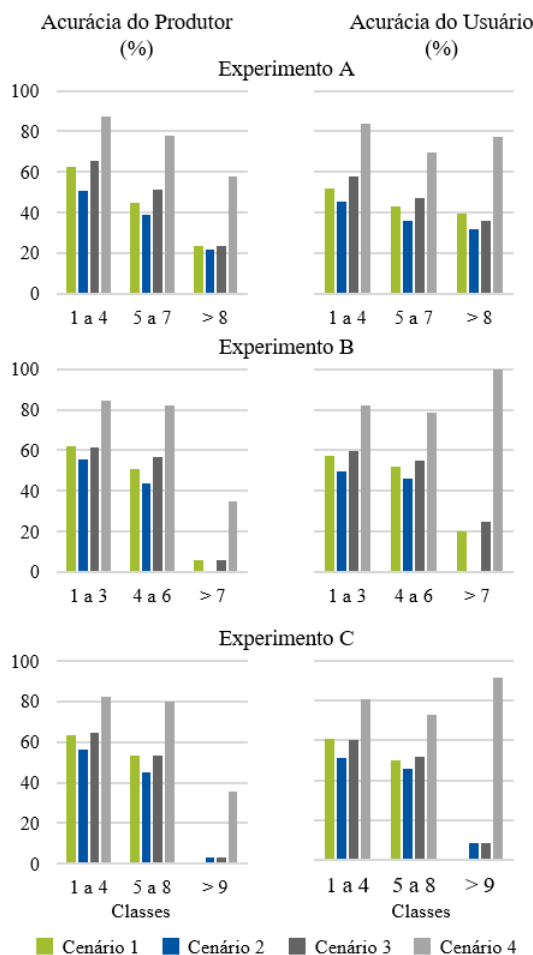


Fig. 2 Acurácias do Produtor e Usuário para cada experimento considerando os quatro cenários analisados.

Em relação à integração com os dados ópticos do Sentinel-2, percebe-se uma melhora na separação entre as classes. Os dados do Sentinel-2 tem como diferencial as bandas na faixa espectral do *red-edge*, que se destacam ao realizar mapeamentos com vegetação, resultando nessa melhora ao integrados com as variáveis SAR [9].

É importante destacar que a utilização apenas da acurácia global para validar o mapeamento não é o suficiente. No caso do experimento B, embora a sua acurácia global tenha sido a maior, nota-se que a classe 3 apresentou altos erros de omissão. Com isso, conclui-se que as classes 1 e 2, cujos valores de acurácia do produtor e usuário foram bastante altos, mascararam o resultado da acurácia global.

Desse modo, o Experimento A se destaca por ter obtido o melhor desempenho, com uma menor confusão na discriminação das classes de idade.

5. CONCLUSÃO

A partir dos resultados observados com esse trabalho, nota-se que a integração entre o Sentinel-1 e Sentinel-2 foi

fundamental para melhorar a classificação da idade de talhões de *Eucalyptus* sp.. Além disso, o experimento A, foi o que apresentou uma melhor distinção entre as classes de idade.

Uma forma de melhorar ainda mais os resultados apresentados, seria a utilização de sensores SAR com maiores comprimentos de onda, como é o caso de sensores banda L, permitindo uma maior interação com a estrutura dos plantios.

8. REFERÊNCIAS

- [1] Instituto Brasileiro de Geografia e Estatística (IBGE), "PEVS - Produção da Extração Vegetal e da Silvicultura," 2021. [Online]. Available: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9105-producao-da-extracao-vegetal-e-da-silvicultura.html?=&t=destaques>. [Accessed 27 out. 2022].
- [2] J. Engelbrecht, A. Theron, L. Vhengani and J. Kemp, "A Simple Normalized Difference Approach to Burnt Area Mapping Using Multi-Polarisation C-Band SAR," *Remote Sensing*, vol. 9, no. 8, p. 764, 2017.
- [3] Agência Espacial Europeia (ESA), "Sentinel Online: Sentinel-1," [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>. [Accessed 27 out. 2022].
- [4] Agência Espacial Europeia (ESA), "Sentinel Online: Sentinel-2 Resolution and Swath," [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>. [Accessed 27 out. 2022].
- [5] SNAP. ESA Sentinel Application Platform V6; European Space Agency (ESA): Paris, France, 2021.
- [6] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, 2001.
- [7] R Core Team, "R: A language and environment for statistical computing," R Foundation for Statistical Computing, Viena, Austria.
- [8] F. M. Henderson and A. J. Lewes, Principles and applications of imaging radar, manual of remote sensing, 3 ed., New York: John Wiley & Sons, 1998, p. 866.
- [9] D. Lu, G. Li, E. Moran, L. Dutra and M. Batistella, "A Comparison of Multisensor Integration Methods for Land Cover Classification in the Brazilian Amazon," *GIScience Remote Sens.*, vol. 48, no. 3, pp. 345-370, 2011.