AVALIAÇÃO DE PREDITORES POTENCIAIS PARA DETECÇÃO DA PERDA DE COBERTURA FLORESTAL

Adilson Luiz Nicoletti[1], Laio Zimermann Oliveira[1,2], Daniel Augusto da Silva[1,3], Artur Ricardo Bizon[1], Marlon Yuri Andrade[1], Murilo Schramm da Silva[1], Alexander Christian Vibrans[1]

[1]Departamento de Eng. Florestal, Universidade Regional de Blumenau, Rua São Paulo, 3250, Blumenau, SC, Brasil, e-mail: alnicoletti@furb.br, laioo@furb.br, danielaugusto@furb.br, abizon@furb.br, myandrade@furb.br, muriloschramm@furb.br, acv@furb.br. [2]Programa de Pós-graduação em Eng. Florestal, Universidade do Estado de Santa Catarina, Av. Luiz de Camões, 2090, Lages, SC, Brasil. [3]Programa de Pós-graduação em Eng. Florestal, Universidade Regional de Blumenau, Rua São Paulo, 3250, Blumenau, SC, Brasil.

RESUMO

Em Santa Catarina/Brasil, um mapeamento florestal recente precisa ser atualizado. Nesse contexto, este estudo avaliou amostras de pixels Landsat-8 (e bandas artificias) da classe "floresta" no ano de 2017 que se encontravam em outra classe de uso da terra no ano de 2022. Modelos lineares foram estimados considerando as variáveis "ano" e "tipo florestal" como preditores categóricos. Os resultados sugeriram que amostras coletadas em um dado tipo florestal podem não ser eficazes para detectar perda de cobertura florestal em outros tipos florestais. Os fatores "ano" e interação entre "ano" e "tipo florestal" não mostraram efeitos estatisticamente significativos ($\alpha = 0.05$) sobre a variável infravermelho próximo, sugerindo que o uso desse preditor pode ser limitado. O estudo reforça a importância de uma amostragem específica para cada tipo florestal e recomenda investigar os usos da terra após a retirada da floresta para melhor entender a resposta do infravermelho próximo.

Palavras-chave **—** supressão florestal, modelo linear de efeitos mistos, banda artificial, atualização de mapeamento.

ABSTRACT

In Santa Catarina/Brazil, a recent forest mapping needs updating. In this context, this study evaluated Landsat-8 pixel samples (and artificial bands) from the "forest" class in 2017 that were in another land-use class by 2022. Linear models were estimated using "year" and "forest type" as categorical predictors. The results suggested that samples collected in one specific forest type are not effective for detecting forest cover loss in other forest types. The factors "year" and the interaction between "year" and "forest type" showed no statistically significant effects ($\alpha = 0.05$) on the near infrared, suggesting that using this predictor may be limited. The study highlights the need for specific sampling for each forest type and investigation of land uses after forest removal to better understand the near-infrared response.

Key words **—** *forest suppression, linear mixed-effects model, artificial band, mapping update.*

1. INTRODUÇÃO

Florestas prestam diversos serviços ambientais como a regulação do clima, proteção do solo, regulagem do ciclo hídrico e conservação da biodiversidade. A perda de biodiversidade compromete a produtividade das florestas [1], consequentemente afetando os serviços ambientais usufruídos pela humanidade.

O conhecimento sobre a extensão das florestas pode ser obtido por meio da classificação e interpretação das imagens de satélites [2]. Santa Catarina/Brasil carecia de informações atualizadas e acuradas sobre a extensão da sua cobertura florestal até a elaboração de um novo mapeamento da cobertura florestal referente ao ano de 2017 e publicado em 2020 [3]. Agora, o desafio é atualizar a cobertura florestal deste mapeamento.

Um programa de monitoramento da cobertura florestal com foco na perda da cobertura pode utilizar algoritmos de detecção de mudanças a nível global. Entre os algoritmos disponíveis, se destacam: 1) GLAD ARD (*Global Land Analysis and Discovery Analysis Ready Data and Tools*) [4]; 2) VeRDET (*Vegetation Regeneration and Disturbance Estimates through Time*) [5]; 3) EWMACD (*Exponentially Weighted Moving Average Change Detection*) [6]; 4) VCT (*Vegetation Change Tracker*) [7]; 5) CCDC (*Continuous Change Detection and Classification*) [8]; 6) LandTrendr (*Landsat-based detection of Trends in Disturbance and Recovery*) [9]. Apesar do aprimoramento das plataformas de alguns desses algoritmos, permitindo uma interação mais intuitiva e direta com os seus usuários, entender e aplicar esses algoritmos em nível regional podem ser complexos. Em parte, porque diferentes tipos florestais apresentam respostas espectrais distintas, o que pode diminuir a acuraria desses algoritmos.

A detecção das áreas com perda da cobertura florestal pode ser realizada por meio da classificação supervisionada de pares de imagens (imagem do ano base e imagem do ano de interesse) e amostras de verdade terrestre. Essas imagens são compostas por faixas espectrais (bandas) que capturam a reflectância do alvo terrestre na superfície da terra e por índices gerados a posteriori a partir de cálculos matemáticos de bandas espectrais, resultando em bandas artificiais.

O objetivo deste estudo foi avaliar um conjunto de valores espectrais e índices das amostras de treino para os anos 2017 (floresta) e 2022 (perda de floresta), os quais são potenciais preditores para a detecção de áreas que sofreram perda da cobertura florestal no período. A hipótese central deste estudo é que amostras coletadas em um determinado tipo florestal da Mata Atlântica podem não ser úteis para detectar perda da cobertura florestal em outro tipo florestal no mesmo bioma.

2. MATERIAIS E MÉTODOS

2.1. Área de estudo

A área de estudo compreende sete cartas (comumente chamadas de "folhas") do Mapeamento Sistemático Brasileiro na escala 1:100.000, cada uma com aproximadamente 2.700 km². Essas folhas foram selecionadas visando abranger os três principais tipos florestais do estado de Santa Catarina/Brasil, descritos por Klein [10] (Figura 1).



Figura 1. Área de estudo.

2.2. Metodologia

Foram utilizadas imagens do sensor OLI (Landsat-8) disponibilizadas na plataforma *Google Earth Engine* do ano de 2017 e de 2022. As imagens possuem correções geométricas e atmosféricas a nível de reflectância da superfície [11]. As imagens referentes ao ano de 2017, foram as mesmas utilizadas no Mapeamento da Cobertura Florestal de Santa Catarina [3]. As imagens referentes ao ano de 2022 foram selecionadas entre 1 de novembro e 31 de dezembro de 2022 expandindo até o mês de setembro, quando necessário, devido à presença de nuvens.

As bandas espectrais foram: azul (B2) (0,452 – 0,512 µm), verde (B3) (0,533 – 0,590 µm), vermelho (B4) (0,636 – 0,673 µm), infravermelho próximo (B5) – NIR (0,851 – 0,879 µm), infravermelho médio 1 (B6) – SWIR1 (1,566 – 1,651 µm) e infravermelho médio 2 (B7) – SWIR2 (2,107 – 2,294 µm). Além das bandas espectrais, foram geradas bandas artificiais baseadas em índices de vegetação, água e estresse hídrico (Tabela 1).

Índice	Descrição do índice	Autor
NDVI	Índice de Vegetação por Diferença Normalizada	[12]
NBRI	Índice de Queimada Normalizada	[13]
NDWI1	Índice de Água de Diferença Normalizada	[14]
NDWI2	Índice de Água de Diferença Normalizada	[15]
EVI2	Índice de Vegetação Aprimorado 2	[16]
CAI	Índice de absorção de celulose	[17]
DSWI1	Índice de Estresse Hídrico por Doença	[18]

Tabela 1. Índices utilizados na seleção de amostras em áreas de perda da cobertura de floresta nativa em Santa Catarina.

As amostras de verdade de terreno de perda de floresta nativa após o ano base de 2017 foram obtidas dos polígonos de desmatamento publicados pelo Atlas dos Remanescentes Florestais da Mata Atlântica [19] e dos polígonos do MapBiomas Alerta (alerta.mapbiomas.org), que fornecem dados desde 2019. Os polígonos foram convertidos em pontos pela técnica de rasterização com base na imagem de 30 m de resolução espacial. Ao todo, foram considerados 1.519 pontos de floresta nativa (em 2017) que deixaram essa classe de uso da terra em 2022 (Tabela 2). As folhas SG-22-Y-A-IV e SG-22-Y-C-I foram unificadas (SG-22-Y-A-IV-C-I) por conterem áreas pequenas do território catarinense.

Tipo florestal	Folha	Número de polígonos	Número de pontos/pixels
FED	SG-22-Y-A-IV-C-I	19	191
	SG-22-Y-C-II	10	238
FOD	SG-22-Z-B-IV	6	65
	SH-22-X-B-I	36	331
FOM	SG-22-Y-B-IV	25	437
	SG-22-Z-A-I	16	257
	Total	112	1.519

Tabela 2. Distribuição dos pontos/pixels por tipo florestal, folha e polígono. Floresta Estacional Decidual (FED), Floresta Ombrófila Densa (FOD) e Floresta Ombrófila Mista (FOM).

Modelos lineares de efeitos mistos foram utilizados para testar a hipótese de que amostras de verdade de terreno coletadas em um dado tipo florestal podem não ser úteis para detectar perda da cobertura de floresta nativa em outro tipo florestal. Os valores dos pixels em dada banda ou índice nos anos de 2017 (floresta) e 2022 (perda de floresta) foram definidos como a variável resposta. As variáveis categóricas "ano" (2017 e 2022) e interação entre "ano" e "tipo florestal" (FOD, FOM e FED) foram definidas como efeitos fixos. Foram incluídos no modelo efeitos aleatórios aninhados, nesta hierarquia: "folha", "agrupamento" e "pixel". O primeiro nível corresponde às folhas conforme Figura 1; o segundo corresponde ao conjunto de pixels numa mesma área

(polígono) de perda de floresta; e o terceiro corresponde à identidade do pixel, especificando, portanto, que cada pixel tem medidas repetidas (anos 2017 e 2022). Os modelos foram submetidos à análise de variância (ANOVA) sequencial visando testar a significância dos efeitos fixos ($\alpha = 0.05$). Os modelos foram estimados com auxílio do pacote "nlme" do R [20].

3. RESULTADOS E DISCUSSÃO

Médias por ano e tipo florestal para as bandas espectrais e índices são apresentadas nas Figuras 2 e 3, respectivamente.

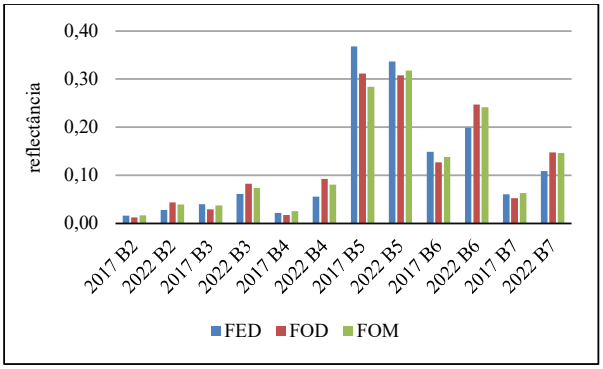

Figura 2. Médias espectrais das amostras de floresta em 2017 e da perda de floresta em 2022 por tipo florestal.

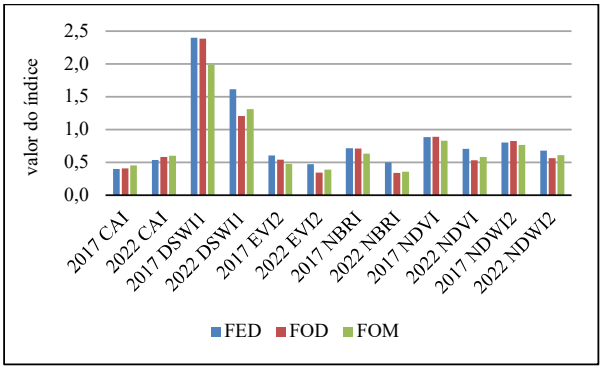

Figura 3. Médias dos índices das amostras de floresta em 2017 e da perda de floresta em 2022 por tipo florestal.

De acordo com as ANOVAs aplicadas aos modelos lineares estimados, o fator "ano" teve um efeito estatisticamente significativo em todas as bandas e índices, com exceção da B5 (Tabela 3). A interação entre os fatores "ano" e "tipo florestal" também mostrou um efeito estatisticamente significativo em todas as bandas, com exceção da B5 (Tabela 3). O modelo para o índice NDWI1 não convergiu.

Banda/Índice	Ano	Ano × Tipo florestal
B4	**< 0.001**	**< 0.001**
B5	0.0638	0.1033
B6	**< 0.001**	**< 0.001**
B7	**< 0.001**	**< 0.01**
CAI	**< 0.001**	**< 0.001**
DSWI1	**< 0.001**	**< 0.001**
EVI2	**< 0.001**	**< 0.05**
NBRI	**< 0.001**	**< 0.001**
NDVI	**< 0.001**	**< 0.001**
NDWI1	NA	NA
NDWI2	**< 0.001**	**< 0.001**

Tabela 3. P-valor associado à estatística F para cada fator testado, onde "Ano × Tipo florestal" é a interação entre os dois fatores. Valores em negrito são estatisticamente significativos ($\alpha = 0.05$). O modelo para o índice NDWI1 não convergiu.

Efeitos significativos do fator "ano" nas bandas espectrais e artificiais eram esperados, uma vez que as amostras em 2017 continham floresta enquanto em 2022 não continham floresta. O efeito não significativo do fator "ano" na B5 (infravermelho próximo) sugere que essa banda não deve ser utilizada como a única variável para detecção da perda da cobertura de floresta nativa. O infravermelho é utilizado no cálculo de diversos índices, com exceção do CAI. Apesar disso, o uso da B5 no cálculo dos índices não fez com que o fator "ano" apresentasse um efeito não significativo sobre eles.

A interação entre os fatores "ano" e "tipo florestal" sugere que os três principais tipos florestais encontrados em Santa Catarina descritos por Klein [10] possuem peculiaridades que devem ser consideradas durante a amostragem para a detecção de perda da cobertura florestal. Isto significa, por exemplo, que amostras coletadas na Floresta Ombrófila Mista podem não ser úteis na detecção de perda de floresta na Floresta Ombrófila Densa. O efeito significativo da interação entre "ano" e "tipo florestal" sugere que a classificação de imagens deve levar em consideração características locais, corroborando a divisão territorial utilizada por Vibrans et al. [3] durante o mapeamento da cobertura florestal de Santa Catarina.

A interação entre esses fatores também não mostrou efeitos significativos sobre a B5. Esse resultado pode ser explicado pelas classes de cobertura da terra em 2022, as quais podem ser reflorestamento, agricultura ou regeneração natural de floresta nativa. Nesse sentido, sabe-se que a vegetação em geral reflete mais energia na faixa do infravermelho próximo [21].

5. CONCLUSÕES

Amostras de treino a serem utilizadas na detecção de perda da cobertura florestal nativa devem incluir valores espectrais em diferentes períodos (ano base e de interesse). As amostras

devem ter representatividade local, ou seja, amostras coletadas em um tipo florestal não devem ser utilizadas em outro tipo florestal.

Dos preditores avaliados, apenas a banda espectral correspondente à faixa do infravermelho próximo (B5) não parece ser útil para detectar perda de cobertura florestal nativa. Apesar dessa banda ser utilizada em diversos índices, o uso dessa variável por si só não é recomendado. Uma futura investigação das classes de uso da terra após a retirada da floresta nativa poderá esclarecer o comportamento do infravermelho próximo observado neste estudo.

6. REFERÊNCIAS

[1] Liang, J., Crowther T. W., Picard, N., et al. Positive biodiversity-productivity relationship predominant inf global forests. Science 354 (6309), 2016.

[2] Köhl, M., Magnussen, S.S., Marchetti, M. *Sampling Methods, Remote Sensing and GIS Multiresource Forest Inventory*. Springer, Heidelberg, Alemanha, 372p. 2006.

[3] Vibrans, A. C., Nicoletti, A. L., Liesenberg, V., Refosco, J. C., Kohler, L. P. A., Bizon, A .R., Lingner, D. V., Bosco, F. D., Bueno, M .M., Silva, M. S., Pessatti, T. B. MonitoraSC: um novo mapa de cobertura florestal e uso da terra do estado de Santa Catarina. *Agropecuária Catarinense*, v. 34, p. 42-48, 2021.

[4] Potapov, P., Hansen, M. C., Kommareddy, I., Kommareddy, A., Turubanova, S., Pickens, A., Adusei, B., Tyukavina, A., Ying, Q. Landsat analysis ready data for global land cover and land cover change mapping. *Remote Sensing*, v. 12(3), 426, 2020.

[5] Hughes, M. J., Kaylor, S. D., Hayes, D. J. Patch-based forest change detection from Landsat time series. *Forests*, v. 8, n. 5, p. 166, 2017.

[6] Brooks, E. B., Wynne, R. H., Thomas, V. A., Blinn, C. E., Coulston, J. W. On-the-fly massively multitemporal change detection using statistical quality control charts and Landsat data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 6, p. 3316-3332, 2014.

[7] Huang, C., Goward, S. N., Masek, J. G., Thomas, N., Zhu, Z., Vogelmann, J. E. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. *Remote Sensing of Environment*, v. 114, n. 1, p. 183-198, 2010.

[8] Zhu, Z., Woodcock, C. E. Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment*, v. 144, p. 152-171, 2014.

[9] Kennedy, R. E., Yang, Z., Cohen, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr - Temporal segmentation algorithms. *Remote Sensing of Environment*, v. 114, n. 12, p. 2897-2910, 2010.

[10] Klein, R. M. Mapa fitogeográfico do estado de Santa Catarina. Itajaí, SC. 24p. (SUDESUL, FATMA, HBR, Flora Ilustrada Catarinense, 5), 1978.

[11] USGS – United States Geological Survey. "Product guide – Landsat 8 surface reflectance code (LaSRC) product". *Department of Interior – United States*, version 4.3, 40p. 2018.

[12] Rouse, J. W., Haas, R. H., Scheel, J. A., Deering, D. W. Monitoring Vegetation Systems in the Great Plains with ERTS. In: *Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium*, v. 1, p. 48-62, 1974.

[13] Key, C. H., Benson, N., Ohlen, D., Howard, S., Mckinley, R., Zhu, Z. The normalized burn ratio and relationships to burn severity: Ecology, remote sensing and implementation. In: GREER, J. D. (Ed.). *Rapid Delivery of Remote Sensing Products; Proceedings of the Ninth Forest Service Remote Sensing Applications Conference*. San Diego: American Society of Photogrammetry and Remote Sensing, Bethesda, MD, 2002.

[14] Gao, B. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, v. 58, n. 3, p. 257-266, 1996.

[15] McFeeters, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, v. 17, p. 1425–1432, 1996.

[16] Jiang, Z., Huete, A. R., Didan, K., Miura, T. Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, v. 112, n. 10, p. 3833-3845, 2008.

[17] Nagler, P. L., Inoue, Y., Glenn, E. P., Russ, A. L., Daughtry, C. S. T. Cellulose absorption index (CAI) to quantify mixed soil–plant litter scenes. *Remote Sensing of Environment*, v. 87, n. 2-3, p. 310-325, 2003.

[18] Apan, A., Held, A., Phinn, S., Markley, J. Formulation and Assessment of Narrow-Band Vegetation Indices from EO-1 Hyperion Imagery for Discriminating Sugarcane Disease. In: *Proceedings of the 2003 Spatial Sciences Institute Biennial Conference: Spatial Knowledge Without Boundaries (SSC2003)*, Canberra, Australia, 22–27, p. 1–13, 2003.

[19] Fundação S.O.S Mata Atlântica. Atlas dos remanescentes florestais da Mata Atlântica, período 2020–2021. *Relatório Técnico*. Fundação S.O.S. Mata Atlântica / Instituto Nacional de Pesquisas Espaciais. São Paulo. 72p. 2022.

[20] Pinheiro, J., Bates, D., DebRoy, S., Sarkar, D., R Core Team. nlme: Linear and Nonlinear Mixed Effects Models. 2021.

[21] Florenzano, T. G. Iniciação em sensoriamento remoto. São Paulo: Oficina de Textos, 3. ed. ampl. e atual. 129p. 2011.