



Apresentação de Artigo: Evaluating Forest Disturbance Detection Methods based on Satellite Image Time Series for Amazon Deforestation Alerts

Autores:

Flávio Belizário da Silva Mota

Karine Reis Ferreira

Maria Isabel Sobral Escada

Aluno:

Marcus Vinicius Gonçalves da Silva

The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLVIII-3-2024
ISPRS TC III Mid-term Symposium "Beyond the canopy: technologies and applications of remote sensing", 4–8 November 2024, Belém, Brazil

Evaluating Forest Disturbance Detection Methods based on Satellite Image Time Series for Amazon Deforestation Alerts

Flávio Belizário da Silva Mota¹, Karine Reis Ferreira¹, Maria Isabel Sobral Escada¹

¹ Earth Observation and Geoinformatics Division, National Institute for Space Research (INPE),
São José dos Campos, SP 12227-010, Brazil
(flavio.mota, karine.ferreira, isabel.escada)@inpe.br


Mota, F. B. D. S., Ferreira, K. R., and Escada, M. I. S.: Evaluating Forest Disturbance Detection Methods based on Satellite Image Time Series for Amazon Deforestation Alerts, **Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.**, XLVIII-3-2024, 357–364, <https://doi.org/10.5194/isprs-archives-XLVIII-3-2024-357-2024>, 2024.

Introdução

DISTÚRBIOS FLORESTAIS

São caracterizados pela mudanças, no espaço e tempo, de padrões característicos de um ecossistema, incluindo ciclo hidrológico, estocagem de carbono, diminuição na cobertura vegetal, dentre outros fatores (LAPOLA et al. 2023; OLIVEIRA et al., 2024; RODRIGUES, 2024).

DISTÚRBIOS FLORESTAIS



Fonte: LAPOLA et al. (2023)

SENSORIAMENTO REMOTO

O sensoriamento remoto se consolidou em uma importante ferramenta para a identificação e monitoramento nas florestas (ALMEIDA et al., 2022).

Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (**PRODES**); Sistema de Detecção de Desmatamento em Tempo Real (**DETER**), gerenciado pelo Instituto Nacional de Pesquisas Espaciais (**INPE**)


SENSORIAMENTO REMOTO

A utilização de séries temporais através de cubos de dados permite a captação da variação ao longo do tempo, No Brasil o INPE criou o programa Brazil Data Cube (BDC) proporcionando o acesso a séries de imagens de satélites (CARRERO et al., 2020)



SENSORIAMENTO REMOTO

A utilização de algoritmos para a identificação desses distúrbios vem se tornando cada vez mais frequentes quando relacionado ao monitoramento florestal (STAHL et al., 2023).



Fonte: Adaptado de Simões et al. (2021)


Nome do Algoritmo	Sigla	Característica	Autores
Breaks For Additive Season and Trend	BFAST	Decompõe a série temporal em componentes sazonais, de tendência e ruído para detectar quebras estruturais associadas a distúrbios; indicado para ambientes com forte sazonalidade, mas sensível a lacunas causadas por nuvens.	Verbesselt et al. (2012)
Continuous Change Detection and Classification	CCDC	Detecta quebras estatísticas na série temporal para monitoramento contínuo de mudanças no uso do solo, atualizando o modelo com novas observações; pode confundir mudanças naturais com distúrbios.	Zhu e Woodcock (2014)
Continuous Monitoring of Land Disturbance	COLD	Aprimora o CCDC ao incorporar múltiplas bandas espectrais, índices de vegetação e técnicas avançadas de remoção de ruído; detecta tanto mudanças sutis quanto abruptas, com alta precisão espacial.	Zhu et al. (2020)
Stochastic Continuous Change Detection	SCCD	Usa um modelo de espaço de estados para tratar tendências e sazonalidades como processos estocásticos, melhorando a detecção em tempo real, reduzindo falsos positivos e operando eficientemente em áreas com alta nebulosidade.	Ye et al. (2021)
Long Short-Term Memory	LSTM	Emprega redes neurais recorrentes especializadas para capturar dependências de curto e longo prazo na série temporal; detecta perturbações ao comparar previsões e observações; exige configuração detalhada da arquitetura da rede.	Kong et al. (2018)

OBJETIVO DO TRABALHO

O estudo avalia métodos automatizados de detecção de distúrbios florestais por meio de séries temporais de imagens de satélite, comparando algoritmos para identificar eventos de desmatamento na Amazônia.

Metodologia


ÁREA DE ESTUDO




- **Localização:** Apuí e Novo Aripuanã, sul do Amazonas, Brasil
- **Expansão do desmatamento:** Apuí (+259,63 km²), Novo Aripuanã (+110,33 km²)
- **Influências externas:** Expansão agropecuária e infraestrutura

Fonte: MOTA et al. (2024)

METODOLOGIA



METODOLOGIA



METODOLOGIA


LANDSAT-8/OLI

- Ano de 2017 a 2020
- Composto temporal de 16 dias do Landsat
- Regularizado a cada 1 mês
- Séries temporais das bandas espectrais: Vermelho, Verde, Azul, NIR, SWIR1, SWIR2 e QA PIXEL



Brazil Data Cube


METODOLOGIA



PROCESSAMENTO DOS DADOS

Nome do Algoritmo	Algoritmo	Processamento Aplicado
Breaks For Additive Season and Trend	BFAST	• Remoção de pixels com >60% de cobertura de nuvem • Interpolação linear obrigatória (preencher buracos na série NDVI)
Continuous Change Detection and Classification	CCDC, COLD, SCCD	• Não fazem interpolação externa • Usam diretamente as bandas e internamente filtram as observações usando a banda QA (informações de qualidade dos pixels). Eles ignoram pixels com nuvens, sombras ou problemas.
Continuous Monitoring of Land Disturbance	LSTM	• Igual ao BFAST: precisa de séries temporais contínuas • Interpolação linear é necessária.

METODOLOGIA




MÉTODOS DE DETECÇÃO DE DISTÚRBIOS

Os métodos aplicados, incluindo **CCDC**, **COLD** e **SCCD**, utilizou séries temporais das bandas espectrais Vermelho, Verde, Azul, NIR, SWIR1, SWIR2 e QA. Em contraste, o **BFAST** e o **LSTM** métodos usaram apenas séries temporais de NDVI.

Algoritmo	Bandas Usadas
BFAST	Apenas NDVI
CCDC	Bandas espectrais completas: Red, Green, Blue, NIR, SWIR1, SWIR2 + QA (qualidade dos pixels)
COLD	Bandas espectrais completas: Red, Green, Blue, NIR, SWIR1, SWIR2 + QA
SCCD	Bandas espectrais completas: Red, Green, Blue, NIR, SWIR1, SWIR2 + QA
LSTM	Apenas NDVI

METODOLOGIA



AValiação dos Resultados

- **Fonte de validação:** Dados do sistema DETER foram utilizados para avaliar a consistência dos métodos de detecção de perturbações.
- **Critério de análise:** Comparação entre pixels identificados como perturbados por cada método e os polígonos de alerta do DETER de 2020.
- **Limitação da avaliação:** A validação é parcial, pois verifica a concordância com os alertas DETER, não a precisão dos algoritmos.
- **Objetivo da análise:** Identificar a compatibilidade entre os métodos automatizados e os alertas oficiais de monitoramento.

PROCESSAMENTO DOS DADOS

Polígono DETER: Foi selecionado um polígono DETER em buffer, marcando um alerta emitido em 21 de maio de 2020. Desse polígono os pixels das séries temporais foram extraídos para serem aplicados nos algoritmos.



17 de Junho de 2019


ALERTA DETER:
21 de Maio de 2020



16 de Junho de 2020

RESULTADO

RESULTADOS



Resultados dos métodos de detecção de distúrbios dentro o alerta de polígono DETER em buffer emitido em 21 de maio de 2020 :

- **Polígono DETER (a)**
- **BFAST (b)**
- **CCDC (c)**
- **LSTM (d)**
- **COLD (e)**
- **SCCD (f)**

Fonte: MOTA et al. (2024)

RESULTADOS

CLASSIFICADOR	CONCORDÂNCIA	JUSTIFICATIVA
SCCD	85%	Usa um modelo que considera tanto as variações normais quanto as inesperadas, identificando as mudanças de forma consistente.
LSTM	83%	Utiliza redes neurais que aprendem os padrões do tempo; detecta as mudanças de forma robusta se os parâmetros estiverem bem ajustados.
COLD	82%	Combina informações de várias bandas e filtra ruídos, melhorando a identificação mesmo em condições difíceis.
CCDC	75%	Baseia-se em métodos estatísticos, mas pode detectar as mudanças com um pouco de atraso e variar entre pixels.
BFAST	72%	Usa apenas o NDVI para identificar alterações, o que pode deixar passar mudanças sutis e ser prejudicado por dados faltantes.

CONCLUSÃO

CONCLUSÃO

- Os métodos multi-banda, especialmente o **SCCD** (85%) e o **COLD** (82%), apresentaram a maior concordância com os alertas do sistema DETER, comprovando sua eficácia na identificação de perturbações florestais.
- O **LSTM** registrou uma boa performance (83%), destacando o potencial do *deep learning* para capturar padrões temporais, embora requeira um ajuste de sua configuração.
- O **BFAST**, que utiliza somente o NDVI, teve a menor concordância (72%), evidenciando limitações perante lacunas de dados e cobertura de nuvens.
- A integração de múltiplas bandas espectrais e o processamento avançado das séries temporais se mostraram fundamentais para melhorar a precisão geral dos métodos.

TRABALHOS FUTUROS

TRABALHOS FUTUROS

- **Aprimoramento dos Modelos:** Refinar os ajustes dos modelos LSTM e SCCD para melhorar sua robustez e desempenho com menor complexidade.
- **Integração de Sensores:** Combinar dados de outros sensores, como o Sentinel-2, para complementar os dados Landsat e reduzir os efeitos da cobertura de nuvens.
- **Expansão da Abordagem:** Testar a aplicação dos métodos em outras regiões e ecossistemas, avaliando a adaptabilidade e eficácia dos algoritmos em diferentes contextos.

Referências

ALMEIDA, C. A. d.; CÂMARA, G.; MOTTA, M.; GOMES, A.; AMARAL, S. Metodologia utilizada nos sistemas PRODES e DETER-2. 2.ed.. São José dos Campos: INPE, 2022. 010 p.

Carrero, G. C.; Fearnside, P. M.; Do Valle, D. R.; De Souza Alves, C. (2020). Trajetórias de desmatamento em uma fronteira de desenvolvimento na Amazônia brasileira: 35 anos de colonização por assentamentos, mudanças políticas e econômicas e questões fundiárias. *Gestão Ambiental*, 66(6), 966–984. <https://link.springer.com/10.1007/s00267-020-01354-w>

Kong, W.; He, H.; Stapleton, S. (2018). Applying deep learning in land cover change detection based on satellite image time series. *Journal of Applied Remote Sensing*, 12(2), 026020.

LAPOLA, D. M.; PINHO, P.; BARLOW, J.; ARAGÃO, L. E.; BERENGUER, E.; CARMENTA, R.; LIDDY, H. M.; SEIXAS, H.; SILVA, C. V.; SILVA-JUNIOR, C. H. (2023). The drivers and impacts of Amazon forest degradation. *Science*, 379(6630), eabp8622.

Referências

Mota, F. B. D. S., Ferreira, K. R., and Escada, M. I. S.: Evaluating Forest Disturbance Detection Methods based on Satellite Image Time Series for Amazon Deforestation Alerts, Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLVIII-3-2024, 357–364, <https://doi.org/10.5194/isprs-archives-XLVIII-3-2024-357-2024>, 2024.

OLIVEIRA, A. H. M.; MATRICARDI, E. A.; ARAGÃO, L. E. O. C.; FELIX, I. M.; CHAVES, J. H.; MAGLIANO, M. M.; OLIVEIRA JÚNIOR, J. M. B.; VIEIRA, T. A.; SANTOS, L. E.; REIS, L. P.; PEREIRA, D. O. S.; DIAS, C. T. S.; GAMA, J. R. V.; MARTORANO, L. G. (2024). Assessing Forest Degradation Through Remote Sensing in the Brazilian Amazon: Implications and Perspectives for Sustainable Forest Management. Remote Sensing, 16(23), e4557. DOI: <10.3390/rs16234557>. Disponível em: <<http://mtc-m21d.sid.inpe.br/ibi/sid.inpe.br/mtc-m21d/2024/12.23.12.42>>. Acesso em: 28 mar. 2025.

RODRIGUES, É. T. Paisagens florestais associadas a sistemas tecno-produtivos rurais na Amazônia brasileira. 2024. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2024. Disponível em: <<http://urlib.net/ibi/8JMKD3MGP3W34T/4B3TAF2>>.

Referências

SIMOES, R. et al. Satellite image time series analysis for big earth observation data. Remote Sensing, v. 13, n. 13, p. 2428, 2021. Disponível em: <https://doi.org/10.3390/rs13132428>.

Verbesselt, J.; Hyndman, R.; Zeileis, A.; Culvenor, D. (2012). Phenological change detection while accounting for abrupt and gradual trends. Remote Sensing of Environment, 114(3), 792-803.

Ye, S.; Liu, X.; Huang, C.; Zhu, Z.; Gao, F. (2021). A stochastic continuous monitoring approach for detecting land disturbances using remote sensing data. Remote Sensing, 13(4), 735.

Zhu, Z.; Woodcock, C. E. (2014). Continuous monitoring of forest disturbance using all available Landsat imagery. Remote Sensing of Environment, 144, 236-250.

Zhu, Z.; Wang, S.; Woodcock, C. E.; Lei, Y. (2020). Improved monitoring of disturbance and recovery dynamics using a consistent time series model. Remote Sensing of Environment, 238, 111164.

Obrigado