

RESSALVA

Atendendo a solicitação do(a) autor(a), o texto completo desse trabalho será disponibilizado no repositório a partir de 27/02/2028.



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de São José dos Campos
Instituto de Ciência e Tecnologia



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



José Victor Orlandi Simões

**DETECÇÃO DE MUDANÇAS EM ÁREAS AFETADAS POR
DESASTRES AMBIENTAIS: UMA ABORDAGEM INTEGRADA DE
DADOS SAR E APRENDIZADO PROFUNDO**

José Victor Orlandi Simões

**DETECÇÃO DE MUDANÇAS EM ÁREAS AFETADAS POR DESASTRES
AMBIENTAIS: UMA ABORDAGEM INTEGRADA DE DADOS SAR E APRENDIZADO
PROFUNDO**

Dissertação apresentado ao Programa de Pós-graduação da Instituto de Ciência e Tecnologia, Universidade Estadual Paulista (Unesp), Campus de São José dos Campos; Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden), como requisito parcial para a obtenção do título de Mestre.

Área: Desastres naturais. Linha de pesquisa: Instrumentação e análise de dados.

Orientador: Prof. Dr. Rogério Galante Negri

São José dos Campos

2026

Instituto de Ciência e Tecnologia [internet]. Normalização de tese e dissertação [acesso em 2026]. Disponível em <http://www.ict.unesp.br/biblioteca/normalizacao>

Apresentação gráfica e normalização de acordo com as normas estabelecidas pelo Serviço de Normalização de Documentos da Seção Técnica de Referência e Atendimento ao Usuário e Documentação (STRAUD).

Simões, José Victor Orlandi

Detecção de Mudanças em Áreas Afetadas por Desastres Ambientais: Uma Abordagem Integrada de Dados SAR e Aprendizado Profundo / José Victor Orlandi Simões. - São José dos Campos : [s.n.], 2026.
58 f. : il.

Dissertação (mestrado) - Pós-graduação em Desastres Naturais - Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia; Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden), São José dos Campos, 2026.

Orientador: Rogério Galante Negri.

1. Sensoriamento Remoto. 2. Radar de Abertura Sintética. 3. Aprendizado Profundo. 4. Detecção de Mudanças. I. Negri, Rogério Galante, orient. II. Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, São José dos Campos. III. Universidade Estadual Paulista 'Júlio de Mesquita Filho' - UNESP. IV. Universidade Estadual Paulista (UNESP). V. Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden). VI. Título.

IMPACTO POTENCIAL DESTA PESQUISA

A pesquisa apresentada concentra-se na integração de representações baseadas em grafos e técnicas de aprendizado profundo para a detecção não supervisionada de mudanças ambientais a partir de séries temporais de imagens SAR, com aplicações em diferentes regiões do Brasil impactadas por desastres naturais. Com potencial para gerar impactos relevantes em múltiplas áreas, o método proposto aprimora a precisão na identificação de regiões afetadas por eventos extremos, como deslizamentos e inundações, mesmo em contextos com escassez de dados de referência. Ao permitir a detecção de mudanças, com alta coerência espacial frente a ruídos e variações locais, a abordagem proposta contribui diretamente para a melhoria de sistemas de alerta precoce, monitoramento contínuo e resposta a emergências. Sua natureza não supervisionada e modular também favorece a adaptação a diferentes contextos geográficos, sensores e tipos de mudança, ampliando o potencial de uso operacional. Além disso, a utilização de grafos de visibilidade temporal e redes neurais em grafos representa um avanço metodológico no campo da análise de séries temporais de sensoriamento remoto, promovendo novas possibilidades para a modelagem de padrões espaço-temporais complexos sem necessidade de dados rotulados. Dessa forma, a pesquisa contribui tanto para o fortalecimento da ciência aplicada em sensoriamento remoto quanto para o desenvolvimento de soluções tecnológicas voltadas à gestão de riscos ambientais, planejamento territorial e formulação de políticas públicas baseadas em evidências.

POTENTIAL IMPACT OF THIS RESEARCH

This research focuses on the integration of graph-based representations and deep learning techniques for unsupervised detection of environmental changes from SAR image time series, with applications in disaster-affected regions of Brazil. The proposed method has the potential to generate significant impacts across multiple domains by enhancing the accuracy of detecting areas affected by extreme events, such as landslides and floods, even in scenarios with limited ground truth data. By enabling the detection of change patterns with high spatial coherence and robustness to noise and local variations, the proposed approach directly supports improvements in early warning systems, continuous environmental monitoring, and emergency response efforts. Its unsupervised and modular nature further facilitates adaptation to different geographic settings, sensor types, and change scenarios, expanding its potential for operational deployment. Moreover, the use of horizontal visibility graphs and graph neural networks represents a methodological advancement in the analysis of remote sensing time series, introducing new possibilities for modeling complex spatiotemporal patterns without requiring labeled data. As such, this research contributes not only to the advancement of applied remote sensing science but also to the development of technological solutions aimed at environmental risk management, land-use planning, and evidence-based policy-making.

SUMÁRIO

RESUMO	6
ABSTRACT	7
1 INTRODUÇÃO	8
2 ARTIGO SUBMETIDO	11
2.1 Simões, J. V. O.; Negri, R. G.; Frery, A. C. Graph-Based Deep Learning Approach for Unsupervised Change Detection in Multitemporal SAR Image Series.	11
3 CONSIDERAÇÕES FINAIS	54
REFERÊNCIAS	55
ANEXOS	57

SIMÕES, J. V. O. Detecção de Mudanças em Áreas Afetadas por Desastres Ambientais: Uma Abordagem Integrada de Dados SAR e Aprendizado Profundo. Dissertação. São José dos Campos: Universidade Estadual Paulista (Unesp), Instituto de Ciência e Tecnologia; Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden), 2026.

RESUMO

A detecção de mudanças em séries temporais de sensoriamento remoto é um componente-chave no monitoramento ambiental, mapeamento da cobertura da terra e gestão de desastres. Imagens de Radar de Abertura Sintética (SAR) são particularmente adequadas para esta tarefa, pois permitem a observação contínua independentemente das condições climáticas ou de iluminação, além de fornecerem sensibilidade à rugosidade da superfície e à umidade. No entanto, as séries temporais SAR também exibem um comportamento radiométrico complexo, incluindo flutuações relacionadas ao ruído *speckle*, dinâmicas temporais não lineares e variações abruptas de retroespalhamento. Essas propriedades tornam a detecção de mudanças desafiadora para métodos que dependem apenas da similaridade de dados ou de trajetórias temporais suaves. Este trabalho apresenta uma proposta não supervisionada baseada em grafos, projetada especificamente para abordar este problema. O método proposto emprega Grafos de Visibilidade Horizontal para codificar a dinâmica estrutural temporal de pixels individuais, a qual é subsequentemente alimentada em uma Rede Neural de Grafos treinada utilizando amostras com pseudo-rótulos derivados de um comitê de algoritmos de detecção de anomalias. Essa estratégia permite que o modelo distinga efetivamente entre casos de mudança e não mudança, mesmo sob condições de alto ruído, como em séries de imagens SAR. A proposta foi avaliada em duas regiões no Brasil afetadas por deslizamentos e inundações. Foram utilizadas séries de imagens obtidas pelo sensor SAR abordo do satélite Sentinel-1 e realizadas comparações com métodos alternativos existentes na literatura. A abordagem proposta superou os métodos concorrentes, alcançando valores de F1-Score e coeficiente kappa de aproximadamente 0,75, enquanto produz mapas de mudança espacialmente coerentes e consistentes.

Palavras-chave: Sensoriamento Remoto. Radar de Abertura Sintética. Aprendizado Profundo. Detecção de Mudanças.

SIMÕES, J. V. O. Change Detection in Environmental Disaster-Affected Areas: An Integrated Approach of SAR Data and Deep Learning. Master Thesis. São José dos Campos: São Paulo State University (Unesp), Institute of Science and Technology; National Center for Monitoring and Early Warning of Natural Disasters (Cemaden), 2026.

ABSTRACT

Change detection in remote sensing time series is a key component in environmental monitoring, land cover mapping, and disaster management. Synthetic Aperture Radar (SAR) imagery is particularly suitable for this task, as it enables continuous observation regardless of weather or illumination conditions, while also providing sensitivity to surface roughness and moisture. However, SAR time series exhibit complex radiometric behavior, including fluctuations associated with speckle noise, nonlinear temporal dynamics, and abrupt backscatter variations. These properties make change detection challenging for methods that rely solely on data similarity or smooth temporal trajectories. This work presents an unsupervised graph-based approach specifically designed to address this problem. The proposed method employs Horizontal Visibility Graphs to encode the temporal structural dynamics of individual pixels, which are subsequently processed by a Graph Neural Network trained using pseudo-labeled samples derived from a committee of anomaly detection algorithms. This strategy allows the model to effectively distinguish between change and no-change conditions, even under high-noise scenarios typical of SAR image time series. The proposed approach was evaluated in two regions in Brazil affected by landslides and floods. Multitemporal SAR imagery acquired by the Sentinel-1 satellite was used, and comparisons were performed against alternative methods available in the literature. The proposed approach outperformed the competing methods, achieving F1-score and Kappa coefficient values of approximately 0.75, while producing spatially coherent and consistent change maps.

Keywords: Remote Sensing. Synthetic Aperture Radar. Deep Learning. Change Detection.

1 INTRODUÇÃO

Mudanças climáticas, impulsionadas pelo aumento da evapotranspiração e pela intensificação do ciclo hidrológico global, têm contribuído para a elevação das temperaturas globais e para o aumento da frequência e severidade de desastres ambientais, causando impactos socioeconômicos e ecológicos significativos (PÖRTNER *et al.*, 2022; SMITH *et al.*, 2022). Nesse contexto, o monitoramento ambiental é essencial para subsidiar estratégias de mitigação e adaptação (OLIVEIRA *et al.*, 2014).

O sensoriamento remoto desempenha papel central no monitoramento da dinâmica ambiental em múltiplas escalas espaciais e temporais, dada sua capacidade de aquisição sistemática de dados em grandes áreas (MORTOJA; YIGITCANLAR, 2020; MUTOWO, 2020; RIBEIRO *et al.*, 2022). Enquanto sensores ópticos são amplamente utilizados, sensores ativos como o Radar de Abertura Sintética (*Synthetic Aperture Radar* - SAR) oferecem vantagens adicionais, incluindo independência de iluminação solar e capacidade de operação sob cobertura de nuvens (WANG *et al.*, 2019). Tais características tornam o SAR particularmente adequado para ambientes tropicais. Contudo, a interpretação de imagens SAR permanece desafiadora devido ao ruído *speckle*, distorções geométricas e à relação não linear entre o retroespalhamento do radar e propriedades da superfície, como rugosidade, umidade e estrutura da vegetação (GIBSON; ENGELBRECHT; RUSH, 2019). Nesse contexto, o uso de séries temporais SAR, adquiridas de forma recorrente sobre a mesma área, tem se tornado cada vez mais comum para capturar a dinâmica temporal da superfície terrestre. Entretanto, essa abordagem exige métodos avançados para extrair informações relevantes de conjuntos de dados SAR multitemporais (BALLÈRE *et al.*, 2021).

Métodos de detecção de mudanças são amplamente empregados para identificar dinâmicas da paisagem comparando imagens de sensoriamento remoto adquiridas em diferentes momentos (NEGRI *et al.*, 2020). Esses métodos podem ser divididos, em linhas gerais, em abordagens supervisionadas e não supervisionadas. Métodos supervisionados dependem de dados de referência rotulados, cuja obtenção pode ser difícil ou custosa em áreas extensas ou inacessíveis (PARELIUS, 2023). Em contrapartida, métodos não supervisionados detectam mudanças sem informações prévias de classe, explorando diferenças estatísticas ou estruturais entre as imagens (MEHMOOD *et al.*, 2022; SHAFIQUE *et al.*, 2022).

Tradicionalmente, a detecção de mudanças não supervisionada baseia-se em pares de imagens bitemporais. Métodos clássicos incluem a Análise de Vetor de Mudança (*Change Vector Analysis* – CVA) (GODOY; NEGRI; AMORE, 2022) e a Análise de Componentes Principais combinada com agrupamento K-Means (CELIK, 2009). Essas abordagens têm sido aplicadas em casos de estudo de monitoramento da cobertura da terra e mapeamento de desastres no Brasil utilizando diferentes sensores (SAPUCCI *et al.*, 2021; OLIVEIRA; NEGRI; SANTOS, 2020). Estudos mais recentes indicam que abordagens baseadas em Aprendizado de Máquina podem superar técnicas tradicionais em cenários complexos (MOÇO *et al.*, 2024).

Desenvolvimentos recentes têm explorado cada vez mais a detecção de mudanças utilizando séries temporais de imagens. O método *Wavelet Energy Correlation Screening* (WECS) (FONSECA *et al.*, 2023) demonstrou alta acurácia e eficiência computacional para o monitoramento de mudanças de longo prazo. Similarmente, a proposta *Temporal Convolutional Autoencoder* (TCAE) detectam mudanças via limiarização de erros de reconstrução obtidos de autoencoders convolucionais aplicados a imagens multitemporais (KALINICHEVA; SUBLIME; TROCEN, 2019). Outras abordagens combinam parâmetros SAR de dupla polarização com modelos probabilísticos e técnicas de agrupamento, alcançando desempenho robusto em áreas urbanas complexas e afetadas por desastres (KIM; LEE; PARK, 2024). Métodos baseados em topologia *fuzzy* e votação majoritária também demonstraram robustez aprimorada em ambientes heterogêneos (SHAO *et al.*, 2021).

Representações baseadas em grafos foram introduzidas recentemente para incorporar dependências espaciais e contextuais além da análise em nível de pixel. Estruturas aprimoradas baseadas em grafos têm sido utilizadas para detectar mudanças modelando relações entre superpixels e atualizando iterativamente probabilidades de mudança (TANG *et al.*, 2024). Outras abordagens representam pares de imagens corrigistradas como grafos interconectados, combinando similaridades espectrais, espaciais e temporais (WU *et al.*, 2023). Esses resultados indicam que a modelagem por grafos pode melhorar a robustez em paisagens heterogêneas.

Paralelamente, métodos baseados em aprendizado profundo têm sido amplamente aplicados em sensoriamento remoto devido à sua capacidade de modelar relações não lineares e padrões complexos. Em particular, Redes Neurais em Grafos (*Graph Neural Networks* – GNNs) permitem incorporar explicitamente relações espaciais e contextuais entre observações, superando limitações de abordagens estritamente baseadas em pixel. Nesse contexto, representações baseadas em grafos têm sido utilizadas para modelar relações entre superpixels e atualizar probabilidades de mudança de forma iterativa (TANG *et al.*, 2024). Outras abordagens representam pares de imagens corrigistradas como grafos interconectados, combinando similaridades espectrais, espaciais e temporais (WU *et al.*, 2023). Esses resultados indicam que a modelagem baseada em grafos pode aumentar a robustez da detecção de mudanças em paisagens heterogêneas.

No domínio temporal, Grafos de Visibilidade Horizontal (*Horizontal Visibility Graphs* – HVG) têm sido utilizados para transformar séries temporais de retroespalhamento SAR em estruturas de grafo que preservam propriedades topológicas associadas à dinâmica temporal. Essa representação permite caracterizar mudanças no comportamento do sinal, como transições abruptas ou alterações persistentes no regime radiométrico. Aplicações recentes demonstraram a capacidade dos HVGs em detectar transições físicas em séries SAR, como mudanças de fase da neve, por meio de análise topológica das séries temporais (BELTRAMONE *et al.*, 2025). Além disso, a modelagem baseada em HVG permite reduzir a dependência de hipóteses paramétricas sobre a distribuição dos dados, tornando-a adequada para séries SAR com comportamento estatístico complexo.

Considerando esses avanços, este estudo propõe uma abordagem não supervisionada

de detecção de mudanças que integra análise de séries temporais SAR, representações HVG e classificação via redes neurais profundas baseadas em grafos. O treinamento do modelo é guiado por pseudo-rótulos derivados do consenso entre múltiplos detectores de anomalias, permitindo reduzir a dependência de dados rotulados. A metodologia foi avaliada em duas áreas no Brasil recentemente afetadas por deslizamentos e inundações, utilizando séries temporais Sentinel-1 adquiridas antes, durante e após os eventos. As áreas apresentam características geomorfológicas e hidrológicas distintas, permitindo avaliar a robustez do método sob diferentes mecanismos físicos de mudança. O desempenho foi comparado com os métodos WECS e TCAE, considerando métricas quantitativas e análise espacial dos mapas gerados.

3 CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma abordagem não supervisionada para detecção de mudanças em séries temporais de imagens SAR, baseada na integração entre análise temporal estruturada, detecção de anomalias e aprendizado profundo em grafos. A metodologia foi aplicada em áreas brasileiras afetadas por desastres naturais, relacionados a cenários de inundação e deslizamentos, e comparada com métodos já consolidados na análise de séries temporais de sensoriamento remoto.

Os resultados indicaram melhora consistente na identificação das áreas afetadas, tanto nas métricas quantitativas quanto na qualidade espacial dos mapas gerados. Observou-se maior continuidade espacial das regiões classificadas como mudança e melhor correspondência com feições topográficas e hidrológicas das áreas analisadas. Esse resultado é particularmente relevante em aplicações de monitoramento de desastres, nas quais a representação espacial adequada das áreas impactadas é fundamental para subsidiar análises posteriores de risco e planejamento de ações de resposta e mitigação.

Em cenários com alta variabilidade radiométrica e presença significativa de ruído, comuns em séries SAR, a abordagem proposta apresentou maior estabilidade quando comparada a métodos baseados apenas em estatística ou reconstrução temporal. Por outro lado, o método apresenta maior custo computacional, o que pode limitar seu uso em aplicações que exigem processamento rápido ou em larga escala.

Do ponto de vista metodológico, o trabalho explora o uso de representações estruturais para séries temporais, a combinação de múltiplos detectores de anomalia para geração de amostras de treinamento e o uso de redes neurais em grafos para modelagem de dependências espaciais. Essa combinação se mostrou adequada para cenários de desastres naturais, onde os processos de mudança costumam ser heterogêneos no espaço e no tempo.

Como continuidade, trabalhos futuros podem explorar a integração de dados auxiliares, como modelos digitais de elevação e informações de uso e cobertura da terra, além da investigação de representações multiescala e arquiteturas baseadas em atenção para melhorar a modelagem espaço-temporal em ambientes complexos.

REFERÊNCIAS

- BALLÈRE, M. *et al.* SAR data for tropical forest disturbance alerts in French Guiana: Benefit over optical imagery. **Remote Sensing of Environment**, Elsevier, v. 252, p. 112159, 2021.
- BELTRAMONE, G. *et al.* Detecting seasonal snow transitions in SAR time series with horizontal visibility graphs. **Remote Sensing Applications: Society and Environment**, Elsevier BV, p. 101772, nov. 2025. ISSN 2352-9385.
- CELIK, T. Unsupervised change detection in satellite images using principal component analysis and *k*-means clustering. **IEEE geoscience and remote sensing letters**, IEEE, v. 6, n. 4, p. 772–776, 2009.
- FONSECA, R. V. *et al.* Wavelet spatio-temporal change detection on multitemporal SAR images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, 2023.
- GIBSON, L.; ENGELBRECHT, J.; RUSH, D. Detecting historic informal settlement fires with Sentinel 1 and 2 satellite data-two case studies in Cape Town. **Fire Safety Journal**, Elsevier, v. 108, p. 102828, 2019.
- GODOY, L. G. R.; NEGRI, R. G.; AMORE, D. de J. Thresholding process on the dissimilarities between probability models for change detection on remote sensing data. **Journal of Applied Remote Sensing**, Society of Photo-Optical Instrumentation Engineers, v. 16, n. 1, p. 016505–016505, 2022.
- KALINICHEVA, E.; SUBLIME, J.; TROCAN, M. Change Detection in Satellite Images Using Reconstruction Errors of Joint Autoencoders. In: TETKO, I. V. *et al.* (Ed.). **Artificial Neural Networks and Machine Learning – ICANN 2019: Image Processing**. Cham: Springer International Publishing, 2019. p. 637–648. ISBN 9783030305086.
- KIM, M.; LEE, S.-J.; PARK, S.-E. On unsupervised multiclass change detection using dual-polarimetric SAR data. **Remote Sensing**, MDPI, v. 16, n. 15, p. 2858, 2024.
- MEHMOOD, M. *et al.* Remote sensing image classification: A comprehensive review and applications. **Mathematical problems in engineering**, Wiley Online Library, v. 2022, n. 1, p. 5880959, 2022.
- MOÇO, G. A. *et al.* Unsupervised change detection methods applied to landslide mapping: Case study in São Sebastião, Brazil. **Transactions in GIS**, Wiley Online Library, v. 28, n. 8, p. 2626–2638, 2024.
- MORTOJA, M. G.; YIGITCANLAR, T. Local drivers of anthropogenic climate change: Quantifying the impact through a remote sensing approach in Brisbane. **Remote Sensing**, MDPI, v. 12, n. 14, p. 2270, 2020.
- MUTOWO, G. Remote sensing lake level fluctuations in response to a changing climate. **Journal of Water and Climate Change**, IWA Publishing, v. 11, n. 1, p. 30–38, 2020.
- NEGRI, R. G. *et al.* Spectral–spatial-aware unsupervised change detection with stochastic distances and support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 59, n. 4, p. 2863–2876, 2020.

OLIVEIRA, L.; NEGRI, R. G.; SANTOS, L. B. L. Análise de técnicas de detecção de mudança para mapeamento de desastres com uso de dados de sensoriamento remoto. **Revista Brasileira de Cartografia**, v. 72, n. 1, p. 177–189, 2020.

OLIVEIRA, M. T. de *et al.* Regeneration of riparian forests of the brazilian Pantanal under flood and fire influence. **Forest Ecology and Management**, Elsevier, v. 331, p. 256–263, 2014.

PARELIUS, E. J. A review of deep-learning methods for change detection in multispectral remote sensing images. **Remote Sensing**, MDPI, v. 15, n. 8, p. 2092, 2023.

PÖRTNER, H.-O. *et al.* **IPCC, 2022: Summary for Policymakers. In: Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.** Cambridge, UK and New York, NY, USA: Cambridge University Press, 2022.

RIBEIRO, A. F. *et al.* A compound event-oriented framework to tropical fire risk assessment in a changing climate. **Environmental Research Letters**, IOP Publishing, v. 17, n. 6, p. 065015, 2022.

SAPUCCI, G. R. *et al.* Analyzing spatio-temporal land cover dynamics in an atlantic forest portion using unsupervised change detection techniques. **Environmental Modeling & Assessment**, Springer, v. 26, p. 581–590, 2021.

SHAFIQUE, A. *et al.* Deep learning-based change detection in remote sensing images: A review. **Remote Sensing**, MDPI, v. 14, n. 4, p. 871, 2022.

SHAO, P. *et al.* Unsupervised change detection using fuzzy topology-based majority voting. **Remote Sensing**, MDPI, v. 13, n. 16, p. 3171, 2021.

SMITH, G. S. *et al.* Climate change, environmental disasters, and health inequities: the underlying role of structural inequalities. **Current environmental health reports**, Springer, v. 9, n. 1, p. 80–89, 2022.

TANG, Y. *et al.* Enhanced graph structure representation for unsupervised heterogeneous change detection. **Remote Sensing**, MDPI, v. 16, n. 4, p. 721, 2024.

WANG, R. *et al.* How can despeckling and structural features benefit to change detection on bitemporal SAR images? **Remote Sensing**, MDPI, v. 11, n. 4, p. 421, 2019.

WU, J. *et al.* Unsupervised change detection for VHR remote sensing images based on temporal-spatial-structural graphs. **Remote Sensing**, MDPI, v. 15, n. 7, p. 1770, 2023.