



TEMA: Uso de Embeddings para auxílio na detecção de distúrbios

Mestranda: Carla Aparecida de Almeida Paula

Orientador(a): Profa. Karine Reis Ferreira / Prof. Alby Rocha

Disciplina: Geoinformática

1.Introdução

Os embeddings são representações numéricas em forma de vetores que permitem aos modelos de Inteligência Artificial compreender o significado semântico dos dados. Historicamente, os modelos exigiam conjuntos massivos de dados rotulados manualmente para aprender tarefas específicas. Com os Embeddings, conseguimos capturar esse significado mapeando semelhanças físicas por meio de proximidade matemática.

Em vez de apenas identificar padrões isolados, o modelo aprende dinâmicas físicas, espaciais e temporais. Ele passa a entender, por exemplo, o ciclo de crescimento da vegetação, como o clima interfere na visibilidade e como diferentes comprimentos de onda dos sensores interagem entre si.

2. Fundamentação Teórica

2.1 O Papel dos Modelos de Fundação (FM)

Podemos dizer que todo embedding é gerado a partir de um Modelo de Fundação, que possui características fundamentais como: É exposto a milhões de imagens de diversos biomas, estações e sensores. Pode realizar múltiplas tarefas com o mínimo de dados rotulados. Projetado para extrair vetores densos de alta dimensão que capturam a essência profunda dos dados de entrada.

2.2 Tipos de Sensores

No âmbito do sensoriamento remoto, o LIDAR destaca-se como um sensor ativo e um método direto de aquisição de dados. Segundo o Instituto Nacional de Pesquisas Espaciais

([s.d.], on-line), o sistema utiliza fonte própria de energia — o laser — para realizar levantamentos. Essa tecnologia permite a geração precisa de Modelos Digitais de Terreno (MDT) e de Superfície (MDS), sendo amplamente empregada na topografia, na mensuração de volumes edificadas e na caracterização da estrutura da vegetação de forma célere e confiável. Já o sensor Thermal Infrared Sensor (TIRS) do LANDSAT 8, usado para identificação de focos de incêndios, e o uso e ocupação do solo para analisar as possíveis correlações no treinamento de modelos como o AlphaEarth, afirma Copernicus 2024. E, portanto, a eficácia do monitoramento depende da tecnologia empregada sendo esses dois sensores abaixo mais usados:

- SAR (Radar de Abertura Sintética): É uma tecnologia de coleta ativa, que emite pulsos de energia e registra a reflexão da interação com a superfície. Isso permite a geração de imagens de alta resolução sob qualquer condição climática, seja dia ou noite, focando na estrutura física do alvo (florestas, relevo, biomassa).
- Sensores Ópticos: Coletam dados de forma passiva, dependendo da energia solar refletida, o que os torna dependentes de condições atmosféricas favoráveis (ausência de nuvens).

2.3 Monitoramento e Dinâmicas de Detecção

Utilizando imagens de satélites como o CBERS-4A ou Amazonia-1, sistemas de detecção em tempo real (*Near Real-Time* - NRT), como o Deter, conseguem monitorar todo o bioma com alta frequência temporal. É importante notar que existem diferenças fundamentais entre os sistemas: enquanto o Prodes e o MapBiomas funcionam como inventários anuais focados em desmatamento por corte raso, sistemas NRT como o Deter, o GLAD ou o RADD são projetados para o alerta rápido de distúrbios.

Essa distinção metodológica reflete-se nos dados de 2024, onde os sistemas de alerta registraram áreas de alteração maiores do que os inventários. Essa variação ocorre porque sistemas como o Deter capturam evidências de degradação florestal, como cicatrizes de fogo e extração seletiva — eventos que, por não configurarem a remoção completa da vegetação (corte raso), não são o foco principal do mapeamento do Prodes ou MapBiomas.

3. Entendimento do Fluxo de Processamento

O funcionamento desse processo ocorre em três etapas principais como mostra a figura I abaixo:

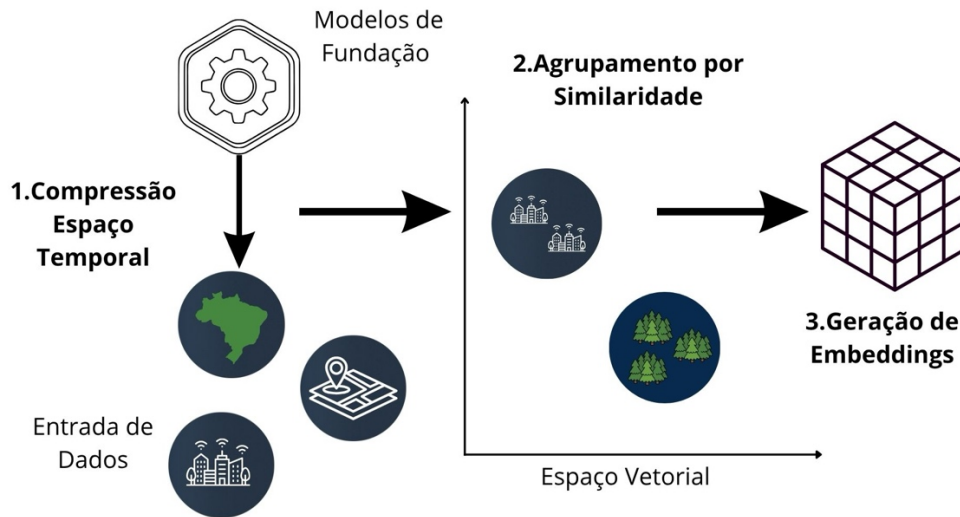


Figura 1- Fluxo de Processamento

1. Compressão Espaço-Temporal: O modelo de fundação recebe informações espectrais complexas (incluindo dados com ruídos ou com nuvens) e as comprime em um vetor matemático limpo e padronizado.
2. Agrupamento por Similaridade: Coberturas de terra idênticas em diferentes continentes são agrupadas no espaço vetorial, enquanto estruturas físicas distintas são afastadas numericamente.
3. Extração de Recursos Automatizada: Os Embeddings substituem processos manuais. Então ao em vez de calcular os índices tradicionais como o NDVI, o modelo extrai automaticamente os recursos mais relevantes para o contexto.

4. Análise do Bioma Amazônico e Desafios

Para distúrbios de grande escala, séries temporais univariadas de pixels independentes (SAR ou ópticos) são suficientes para uma detecção com baixa latência. No entanto, a degradação progressiva, como a exploração madeireira um desafio: por ser um processo gradual que gera clareiras pequenas e esparsas, os alertas tendem a ser fragmentados, o que pode levar sistemas NRT automatizados a ignorarem o evento todo.

5.Objetivos

O objetivo deste trabalho é avaliar a eficácia do uso de *Embeddings* gerados por Modelos de Fundação na detecção de distúrbios ambientais. O intuito é permitir a integração de múltiplos sensores e dados de Sensoriamento Remoto sem a necessidade de processamento ou harmonização individual complexa, mitigando problemas de redundância entre bandas e índices espectrais. Com isso, pretende-se reduzir a dependência de grandes volumes de dados rotulados manualmente e aumentar a precisão na classificação de eventos de distúrbios.

6.Metodologia

A pesquisa utilizará Python para uma análise estatística preliminar das imagens, com o intuito de caracterizar o comportamento temporal dos sinais de alerta para diferentes classes de distúrbios em diversos sensores. Esta etapa é fundamental para identificar as variáveis e períodos mais representativos antes da aplicação dos modelos.

O trabalho compreende o estudo aprofundado de três tipos de embeddings, analisando seu funcionamento e as variáveis de entrada utilizadas por cada um. Após a definição da área de estudo e o agrupamento das imagens brutas, será realizado o treinamento de modelos de classificação utilizando os *Embeddings* extraídos de Modelos de Fundação.

Referências

Bottani, M., Ferro-Famil, L., Doblas Prieto, J., Mermoz, S., Bouvet, A., Koleck, T., Le Toan, T., 2025. Novel unsupervised Bayesian method for Near Real-Time Forest loss detection using Sentinel-1 (SAR) time series: Assessment over sampled deforestation events in Amazonia and the Cerrado. 331, 115037.

BROWN, Christopher F. *et al.* AlphaEarth Foundations: An embedding field model for accurate and efficient global mapping from sparse label data. [S. l.]: Google DeepMind; Google, 2025. Disponível em: <https://arxiv.org/abs/2507.22291>. Acesso em: 30 abr. 2026.

ROCHA, Alby Duarte; GOMES, Alessandra Rodrigues; SADECK, Luis Waldyr Rodrigues; FERREIRA, Karine Reis. Beyond Alerts: spatiotemporal trade-offs in near-real-time detection systems for forest disturbance in the Brazilian Amazon. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2024.

UNIÃO EUROPEIA. **Conheça os nossos satélites**. Copernicus, 2024. Disponível em: <https://www.copernicus.eu/pt-pt/acerca-do-copernicus/infraestrutura/conheca-os-nossos-satelites>. Acesso em: 1 mai. 2026.